



TEKNILLINEN TIEDEKUNTA

# **VKU2-PROSESSIMALLIEN KARTOITUS, VALIDOINTI JA VERTAILU**

Niilo Pitko

PROSESSITEKNIIKAN KOULUTUSOHJELMA

Diplomityö

Huhtikuu 2020

# TIIVISTELMÄ

VKU2-prosessimallien kartoitus, validointi ja vertailu.

Niilo Pitko

Oulun yliopisto, 2020 Prosessimetallurgian tutkinto-ohjelma

Diplomityö 2020, 131 s. + 8 liitettä

Työn ohjaaja(t) yliopistolla: Eetu-Pekka Heikkinen, Matti Aula

Tämän työn tavoitteena on tarkastella VKU2:lla käytössä olevia prosessimalleja. Prosessimallien avulla on tarkoitus tehostaa valokaariuuniprosessia ja tutkia sitä. Tarkoituksena on aluksi käydä läpi prosessimalleja yleisesti ja sitten siirtyä VKU2:lla käytössä oleviin prosessimalleihin. VKU2-prosessimalleista ja niiden toiminnasta on tavoitteena luoda yhteenveto, jonka lukemalla lukija saa käsityksen niiden toiminnasta. Yhteenvedon laadinta on perusteltua, koska mallien toiminnasta ei ole tällä hetkellä olemassa yhtä julkaisua, josta niiden toiminnasta voi lukea. Työn tutkimusosassa eli validoinnissa tutkitaan mallien toimintaa niistä saatavan datan avulla. Mallinnustuloksia siis verrataan mitattuihin arvoihin. Tilastollisten menetelmien avulla siis tarkastellaan mallien toimintaa, jonka jälkeen validoinnin tuloksia tarkastellaan sanallisesti. Validoinnin aikana on pyritty löytämään virheitä malleista, tarkastelemaan niiden toimintaa eri sulatuksissa ja tutkimaan mitä hyvää malleissa on. Työn lopuksi on esitetty näkemyksiä ja mielipiteitä siitä, kuinka prosessimalleihin tulisi jatkossa suhtautua VKU2:lla. Työn tärkeimmät havainnot ovat se, että malleja ei saa unohtaa eli niitä tulisi ylläpitää ja kehittää jatkuvasti sekä se, millaisia systemaattisia virheitä mallien toiminnassa havaittiin validoinnin aikana.

*Asiasanat: VKU, prosessimallit, validointi, valokaariuuni*

# ABSTRACT

EAF2 process models survey, validation and comparison.

Niilo Pitko

University of Oulu, Degree Programme of Process Metallurgy

Master's thesis 2020, 131 pp. + 8 Appendixes

Supervisor(s) at the university: Eetu-Pekka Heikkinen, Matti Aula

The main goal for this thesis is to review different kind of process models used in EAF2. The purpose of the process models is to enhance the efficiency of the arc furnace process and to gather more information from it. The aim is to create a summary of the EAF2 process models and their operation, so the reader gets an idea of their operation. This is done because there is currently no single publication on how models work that can be read about. In, research section i.e. validation, the operation of the models is studied with the help of the data. The modeling results are thus compared with the measured values. Statistical methods are used to examine the operation of the models, after which the results of the validation are examined orally. In the end, some views and opinions on how process models should be treated at EAF2 in the future are presented. The most important observation of the thesis is that the models should not be forgotten, i.e. they should be maintained and developed continuously, as well as the kind of systematic errors that were found in the process models during validation.

*Keywords: EAF, process models, validation, electric arc furnace*

# ALKUSANAT

Tämä diplomityö on tehty Outokummun Tornion terästehtaalla 11.11.2019– 22.4.2020 välisenä aikana.

Iso kiitos kaikille Outokummun työntekijöille ja Oulun Yliopiston henkilökunnalle avusta tämän työn toteutuksessa. Outokummun työntekijöistä haluan kiittää erikseen DI Topi Ikäheimosta hyvin mielenkiintoisesta aiheesta, jonka tekeminen oli alusta loppuun hyvin mieleistä ja jonka aikana opin paljon uutta. Lisäksi erityisen isot kiitokset DI Niko Hyttiselle diplomityön ohjaamisesta ja kaikesta avusta työn tekemisen aikana. Yliopiston puolelta haluan kiittää ohjaajaani TkT Matti Aulaa ja valvojaani TkT Eetu-Pekka Heikkistä. Eetu-Pekkaa haluan kiittää myös loistavasta ja erityisesti mielenkiintoisesta metallurgian opetuksesta. Metallinjalostajien rahastoa haluan kiittää apurahasta, jonka avulla pystyn rahoittamaan kulkemistani Oulusta Tornioon. Kiitokset ja onnittelut myös melkein DI Juho Toivoniemelle vaihtelevasta seurasta diplomityön teon aikana niin työmatkoilla kuin toimistolla. Näin viimeiseksi kiitokset äitille ja isälle.

Yhteensä 17 opiskeluvuoden jälkeen on vapauttava tunne saattaa tutkinto päätökseen ja valmistua yliopistosta tänä koronaviruksen täyteisenä aikana, joka toi myös oman pienen lisän tämän työn tekemiseen. Loppuun täytyy vielä käyttää mahdollisuus mainostaa itseäni ja tarvetta kauppakorkean Pro gradupaikalle vuodelle 2021.

Oulu, 22.4.2020

*Niilo Pitko*  
Niilo Pitko

# SISÄLLYSLUETTELO

TIIVISTELMÄ

ABSTRACT

ALKUSANAT

SISÄLLYSLUETTELO

MERKINNÄT JA LYHENTEET

1 Johdanto .....	12
2 Ruostumattoman teräksen valmistus valokaariuunissa .....	13
2.1 Tornion terästehdas .....	13
2.2 Terässulatto .....	14
2.3 VKU2 .....	14
2.3.1 Valokaariuunin tehtävä sulatolla .....	14
2.3.2 VKU2:n rakenne .....	15
2.3.3 Panosmateriaalit .....	16
2.4 Prosessivaiheet .....	17
2.4.1 Panostus .....	17
2.4.2 Sulatus .....	18
2.5 Sulatuksen aikana tapahtuvat kemialliset reaktiot .....	19
2.6 Kuona .....	21
3 Valokaariuunin energiatase .....	22
3.1 Energiatase .....	23
3.1.1 Valokaariuunin tasealue .....	23
3.1.2 Valokaariuunin ainetase .....	23
3.1.3 Energiataseen muodostaminen valokaariuunille .....	24
3.2 Prosessin kokonaisenergian kulutukseen vaikuttavat tekijät .....	26
3.2.1 Valokaariuunin panoksen vaikutus kokonaisenergian kulutukseen .....	26
3.2.2 Hyötysuhteiden vaikutus kokonaisenergian kulutukseen .....	27
3.2.3 Kaatolämpötilan vaikutus valokaariuunin energiankulutukseen .....	28
3.2.4 Sulatuksen keston vaikutus energiantarpeeseen .....	29
3.3 Kemiallinen energia .....	29
3.3.1 Happi-kaasupolttimien käyttö valokaariuunissa .....	29
3.3.2 Happilanssaus .....	30
3.3.3 Jälkipoltosta syntyvä kemiallinen energia .....	31
3.4 Häviöt .....	32
3.4.1 Ei-toivotut materiaalit panoksessa .....	32

3.4.2	Jäähdytyskierron lämpösisältö.....	33
3.4.3	Prosessissa syntyvien savukaasujen lämpösisältö .....	33
3.4.4	Lämpösäteilyn aiheuttamat häviöt .....	34
3.4.5	Vuorauksen lämpösisältö.....	34
3.5	Yhteenveto energiantarpeeseen vaikuttavista tekijöistä.....	35
4	Valokaariuunin prosessimallit.....	36
4.1	Offline-mallit.....	36
4.1.1	Energian tarpeen määrittäminen empiirisillä malleilla valokaariuunille .....	36
4.1.2	Köhlen malli .....	37
4.1.3	Adamsin malli.....	39
4.1.4	Carlssonin ja muiden tilastolliset mallit .....	39
4.1.5	Neuroverkkoihin perustuvat mallit .....	40
4.1.6	ThyssenKrupp Nirosta Bochum & Krefeld .....	42
4.1.7	Valokaariuuniprosessin mallinnus taloudellisesta näkökulmasta.....	44
4.1.8	Matemaattinen mallinnus valokaariuunille.....	47
4.1.9	Valokaariuunisimulaattori .....	51
4.1.10	Elektrodien kulumisen mallinnus .....	52
4.1.11	Valokaariuuniprosessin CFD-mallinnus.....	54
4.1.12	Valokaariuunin mallinnus fysikaalisella vesimallilla.....	54
4.2	Ohjausmallit .....	56
4.2.1	Dynaaminen mallinnus valokaariuuniprosessille .....	56
4.2.2	2-tason mallit valokaariuunille PRM.....	57
4.2.3	Siemens VAI SteelExpert .....	60
4.2.4	Panostusmallit.....	60
4.3	Mallien yhteenveto.....	61
5	VKU2-prosessimallit .....	63
5.1	Mistä mallit saavat tarvittavat tiedot .....	64
5.1.1	Tasesulatuksella.....	64
5.1.2	Savukaasujen analysointi.....	64
5.1.3	Qmato .....	64
5.1.4	Analyysit.....	65
5.1.5	Mittalaitteet.....	65
5.2	Panoslaskenta .....	65
5.2.1	Paukku .....	65
5.2.2	SulO .....	66
5.3	2-taso automaatiojärjestelmä VKU2:lla .....	67
5.3.1	Esilaskenta .....	67

5.4 2-tason prosessimallit.....	68
5.4.1 Mallien toiminta ennen sulatusta ja sen aikana .....	69
5.4.2 Energiamalli.....	70
5.5 Sulatusajan optimointimalli .....	70
5.6 MORSEVKU2 .....	72
5.7 Elektrodien kulumismalli .....	74
5.8 ValuA .....	75
5.9 DynArCOS.....	76
5.9.1 Elektrodien säätösystemi ArCOS .....	77
5.9.2 ArCOS ja muita laajasti käytössä olevia valokaaren säätösystemejä. ....	78
5.10 Yhteenveto Torniossa käytettävistä malleista.....	78
6 VKU2-mallien validointi .....	81
6.1 Kaatopaino .....	82
6.1.1 MORSEVKU2 versio 1 .....	82
6.1.2 MORSEVKU2 versio 2 .....	84
6.1.3 Sulatusajan optimointimalli versio 1 .....	85
6.1.4 Sulatusajan optimointimalli versio 2 .....	87
6.1.5 Paukku .....	89
6.1.6 Esilaskenta .....	90
6.2 Kaatolämpötila .....	92
6.2.1 MORSEVKU2 versio 1 .....	92
6.2.2 MORSEVKU2 versio 2 .....	94
6.2.3 Sulatusajan optimointimalli versio 1 .....	95
6.2.4 Sulatusajan optimointimalli versio 2 .....	97
6.2.5 Energiamalli.....	99
6.3 Energiantarve .....	100
6.3.1 MORSEVKU2 versio 1 .....	101
6.3.2 MORSEVKU2 versio 2 .....	102
6.3.3 Sulatusajan optimointimalli versio 1 .....	102
6.3.4 Sulatusajan optimointimalli versio 2 .....	103
6.3.5 Köhlen malli korjauskertoimella .....	103
6.3.6 Energiamalli.....	105
6.4 Teräksen koostumus.....	106
6.4.1 Paukku .....	107
6.4.2 Esilaskenta .....	109
6.4.3 Raffinointimalli.....	110
6.5 Elektrodien kulumismalli .....	111

6.6 Yhteenveto mallien validoinnista.....	112
7 Validoinnin tulosten tarkastelu ja johtopäätökset .....	115
7.1 Ongelmat validoinnissa .....	115
7.1.1 Mallien nykyinen tila.....	115
7.1.2 Ongelmat datassa .....	115
7.2 Mallin hyvyyden perusteet.....	116
7.3 Paukku.....	116
7.4 2-tason prosessimallit.....	117
7.4.1 Energiamalli.....	117
7.4.2 Raffinointimalli.....	118
7.5 MORSEVKU2 .....	118
7.5.1 Kaatopainomallin korjaus .....	118
7.6 Sulatusajan optimointimalli .....	119
7.7 Kilpailevat mallit MORSEVKU2 ja Sulatusajan optimointimalli .....	119
7.8 Köhlen malli.....	120
7.9 Yhteenveto validoinnin tuloksista.....	121
7.9.1 Mallien suurimmat ongelmat yleisesti.....	121
7.9.2 Mallien hyvät ominaisuudet yleisesti .....	121
8 Prosessimallien kehitysideat .....	122
8.1 Mallien toiminnan seuraaminen .....	122
8.2 Täysin uusi malli .....	122
8.3 Simulaattorin kehitys .....	123
8.4 Paukku.....	123
8.5 Sulatusajan optimointimalli ja MORSEVKU2-malli.....	123
8.5.1 Sulatusajan optimointimallin korrelaatiokertoimien tutkiminen .....	124
8.6 Energiamalli ja Köhlen malli .....	124
8.7 Yhteenveto prosessimallien tulevaisuudesta.....	124
9 Yhteenveto .....	126
10 Lähdeluettelo.....	127

#### LIITEET:

Liite 1. Taulukon 8 termit selitettyinä. (Carlsson et al. 2019)

Liite 2. Sulatusajan optimointimallin parametrit. (Thampi 2019)

Liite 3. Demonäkymän historiatiedot.

Liite 4. Onlinenäköymän kaikki mallinnetut ja mitatut parametrit.

Liite 5. Regressioanalyysi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila. (Sulatusajan optimointimalli v1)



Liite 6. Regressioanalyysi: Hiilen, piin, kromin ja nikkelin koostumus reseptissä ja sulassa. (Paukku)

Liite 7. Regressioanalyysi: Kromin ja nikkelin koostumus reseptissä ja sulassa. (Paukku)

Liite 8. Regressioanalyysi: Hiilen, piin, kromin ja nikkelin koostumus reseptissä ja sulassa. (Esilaskenta)

## MERKINNÄT JA LYHENTEET

$\sigma$	Stefan-Boltzmannin vakio
$\varepsilon$	pinnan emissiokykykerroin
$\eta$	hyötysuhe
$\rho$	tiheys
A	pinta-ala
$c_p$	ominaislämpökapasiteetti [kcal/kg·°C]
$C_p$	lämpötilakapasiteetti
E	lämpösisältö
H	entalpia
I	virta
m	massa
n	ainemäärävirta [mol/s]
P	sulatuksessa tuotetut terästonnit
R	sublimoitumiskerroin
$R_o$	hapettumiskerroin
$R^2$	selitysaste
r	korrelaatiokerroin
s	seinämän paksuus [m]
t	aika
V	tilavuusvirtaus [m <sup>3</sup> /h]
T	lämpötila [°C]
AOD	Argon Oxygen Decarburization
CRK	ferrokromikonvertteri
Cr-Ni	austeniittinen ruostumaton teräs
FeCr	ferrokromi
FeNi	ferronikkeli
FeSi	ferropii
kWh	kilowattitunti
kWh/kg	kilowattituntia/kilogramma
kWh/t	kilowattituntia/tonni
kWh/kt	kilowattituntia/kilotonni

kWh/t-min kilowattituntia/tonni per minuutti

romu valokaariuunin panostettava kierrätysmateriaali

THD Total Harmonic Distortion

VKU2 valokaariuuni 2

# 1 JOHDANTO

Ruostumattoman teräksen valmistusprosessi alkaa terässulatolla valokaariuunilta, missä romu sulatetaan valokaarten avulla. Jatkuvasti kasvavien raaka-aine- ja energiakustannusten vuoksi prosessimallien kehitys valokaariuunille on ollut yleinen tapa pyrkiä vähentämään kustannuksia viimeisen 20 vuoden aikana (Pfeifer et al. 2005). Mallien avulla pyritään keräämään tietoa prosessista sekä ohjaamaan sitä tehokkaammin.


Tässä diplomityössä on tarkoitus avata tekijöitä, mitkä vaikuttavat erityisesti valokaariuuniprosessin energiankulutukseen, sekä pohjustaa millaisia malleja maailmalla on tällä hetkellä käytössä ja miten nämä mallit toimivat. Tämän jälkeen esitellään Tornion VKU2:lla käytössä olevat prosessimallit ja käydään läpi niiden toimintaan ja mitä niiden käytöllä on tarkoitus saavuttaa prosessin ohjaamisen ja kehityksen kannalta. Tällä hetkellä ongelmana on se, että VKU2:lla on käytössä useita malleja, mutta kenelläkään ei ole kattavaa kuvaa niiden kaikkien toiminnasta. Tämän diplomityön tarkoituksena on siis kerätä yhteen julkaisuun tietoa VKU2:lla käytettävistä malleista. Samalla käydään läpi tulisiko VKU2:lla olevaa mallikokoelmaa laajentaa malleilla, joita maailmalla on käytössä tällä hetkellä.

Työn tutkimusosassa eli validoinnissa validoidaan prosessimalleja, joista saatiin dataa validointia varten. Validoinnin tuloksia esitetään aluksi kuvaajien avulla, jonka jälkeen kuvaajia avataan laajemmin sanallisesti. Tämän validoinnin tarkoituksena on kerätä tietoa mallien toiminnasta tällä hetkellä. Viimeiseksi tässä työssä on esitetty näkemyksiä siitä kuinka prosessimallien kehitykseen tulisi suhtautua tulevaisuudessa VKU2:lla.

## 2 RUOSTUMATTOMAN TERÄKSEN VALMISTUS VALOKAARIUUNISSA

### 2.1 Tornion terästehdas

Outokumpu Oyj:n Tornion terästehdas on yksi maailman suurimmista ruostumattoman teräksen valmistusyksiköistä. Tornion tehdasalueella sijaitsevat ferrokromisulatto, terässulatto, hiomo, kuumavalssaamo ja kylmävalssaamo. Tornion tehtaan läheisyydessä sijaitsee Kemin kaivos, josta saadaan kromimalmia ferrokromisulaton tarpeisiin. Ferrokromisulatto tuottaa ferrokromia, jota käytetään ruostumattoman teräksen valmistuksessa. Valtaosa ferrokromisulaton tuotteesta käytetään terässulattolla. Terässulaton tuottamat teräsaihiot kuuma- ja kylmävalssataan niiden ominaisuuksien parantamiseksi, minkä jälkeen ne lähetetään asiakkaille. Kuvassa 1 on esitetty Tornion terästehtaan ja terässulaton prosessikaaviot. (Heikkinen & Loukola-Ruskeeniemi 2015)



Kuva 1. Tornion terästehtaan ja terässulaton prosessikaaviot (mukaillen Metallinjalostajat 2014, Oulun yliopisto 2019a).

## 2.2 Terässulatto


Terässulatto koostuu kahdesta tuotantolinjasta, joista linja 1 on aloittanut toiminnan vuonna 1976 ja linja 2 vuonna 2002. Linjan 1 panoskoko on 95 tonnia ja linjan 2 panoskoko on 150 tonnia. Suurimpana erona linjojen välillä on kromikonvertterin käyttö linjalla 1. Kromikonvertteri mahdollistaa sulan ferrokromin käytön terässulatolla, jolloin säästetään energiaa. Ferrokromisulan ongelmana on kuitenkin sen korkea piipitoisuus, jota lasketaan happipuhalluksen avulla CRK:lla. Tämän jälkeen kromikonvertterisula sekoitetaan valokaariuunin sulaan, ja linjojen toiminta on tämän jälkeen hyvin samankaltaista. Linjalla 2 teräksen valmistus alkaa raaka-ainepihalta, jossa valokaariuuniin kerätään panos. Kerätty panos sulatetaan valokaariuunissa, minkä jälkeen se kaadetaan siirtosenkkaan ja kuljetetaan AOD:lle jatkojalostusta varten. AOD-konvertterissa terässulan hiilipitoisuutta lasketaan mellotuksen avulla. Mellotusprosessi tapahtuu puhaltamalla terässulaan hapetta ja inerttiä kaasua. Tämän jälkeen sulasta poistetaan ylimääräinen kuona, se kaadetaan siirtosenkkaan ja toimitetaan senkka-asemalle. Senkka-asemalla terässulaan tehdään lopulliset seostukset ja optimoidaan sulan lämpötila valua varten. Torniossa on käytössä jatkuvavalukone. Terässula lasketaan valusenkan pohjassa olevasta reiästä välialtaaseen ja siitä vesijäähdytetyyn kokilliin. Kokillissa terässula jähmettyy ja sen pintaa jäähdytetään vesisuihkujen avulla. Valmis aihio polttoleikataan haluttuun mittaan ja toimitetaan seuraavaan prosessivaiheeseen. (Metallinjalostajat 2014)

## 2.3 VKU2

### 2.3.1 Valokaariuunin tehtävä sulatolla

Valokaariuunin päätehtävä terässulatolla on sulattaa panos mahdollisimman nopeasti ja energiatehokkaasti optimaaliseen lämpötilaan AOD-konvertteria varten. Terässulaton ollessa kokonaisuus on tärkeää, että valokaariuunin tuottama terässula on koostumukseltaan, lämpötilaltaan ja painoltaan optimaalinen AOD-prosessia varten. Näin onnistutaan minimoimaan AOD-prosessin käsittelyaika. Myös energian kulutuksen kannalta on tärkeää, että valokaariuunin kaatolämpötilat pysyvät halutulla alueella, sillä tällöin onnistutaan käyttämään mahdollisimman vähän sähköenergiaa ja säästämään sulatuskuluissa. Valokaariuuni toimii terässulatolla sekundääristen raaka-aineiden kierrätyskeskuksena. Raaka-aineita uuniin saadaan tehtaan sisäisestä kierrosta ja

ostamalla niitä ulkopuolelta. Haasteina sekundäärisissä raaka-aineissa on tasainen saatavuus ja laatu. Hankalia epäpuhtauksia, joita sekundäärisissä raaka-aineissa esiintyy ovat muun muassa fosfori ja kupari. Kuvassa 2 on esitetty valokaariuuni. (Gramberger & Knapp 2001)



Kuva 2. Valokaariuuni. (mukaillen Fabritius 2009)

### 2.3.2 VKU2:n rakenne

Valokaariuuni 2 on Siemens VAI:n vuonna 2002 toimittama tuotantoyksikkö. Uunin panoskoko on 140 tonnia ja sen nimelliskapasiteetti on 800 000 tonnia sulaa terästä vuodessa, kun kaadosta kaatoon-aika on 60 minuuttia. Uunin halkaisija on 8160 mm, korkeus 5500 mm ja panostilavuus 200 m<sup>3</sup>. Se koostuu neljästä osasta: vesijäähdytetystä holvista ja ylävaipasta sekä tulen kestävillä materiaaleilla vuoratusta pohjasta ja alavaipasta. Holvi koostuu isosta ja pienestä holvista. Iso holvi toimii uunin kantena, ja pienen holvin läpi kulkevat elektrodit. Alavaippa ulottuu 400 mm sulan pinnan yläpuolelle ja se on vuorattu MgO-C-tiilillä. Uunin pohja on vuorattu MgO-massalla. Uunissa ei ole erillistä kuonaluukkua, vaan kuona kaadetaan ulos uunista kaatonokan

kautta. Kaatonokka on valmistettu erillisestä blokista, joka on tehty MgO-tiiliä yhteen sintraamalla. Valokaariuunin pata on kiinnitetty laitteistoon, jonka avulla sula teräs ja kuona on mahdollista kaataa ulos sulatuksen jälkeen. Savukaasut poistuvat uunista holvin päällä olevan vesijäähdytetyn poistoputken kautta. (Gramberger & Knapp 2001)

Prosessissa käytettävä sähköenergia syötetään prosessiin kolmen 710 mm halkaisijaltaan olevan grafiittielektrodin kautta. Elektrodeja kannattelevat elektrodiaarit, jotka on kytketty muuntajaan. Muuntajan avulla valokaaren tehoa voidaan säätää 18 jänniteportaan avulla. Elektrodiaarit on kannatettu kääntyvällä kääntökehällä, jonka ansiosta ne on mahdollista ajaa sivuun panostuksen ajaksi. Vesijäähdytetyn holvin keskellä on tulenkestävillä materiaaleilla vuorattu alue, jonka läpi elektrodit saadaan uunin sisään. Tämä tehdään, jotta kipinöintiä holvin ja elektrodien välillä ei tapahtuisi. Sähköenergian käytön pienentämiseksi uuniin on asennettu happi-kaasupolttimet, joiden avulla panosta voidaan prosessin aluksi lämmittää, ja prosessin lopuksi niiden kautta on mahdollista puhalttaa sulaan happea. Lisäksi holvissa on aukkoja, joiden läpi injektoidaan kalkkia prosessin aikana. Kaikki muut uunin rakenteet paitsi uunin alavaippa on vesijäähdytetty. Ylävaipan jäähdytyksestä vastaa 15 vesipaneelia. Myös elektrodien kannatinarmit ja virtakaapelit on vesijäähdytetty. Jäähdytysvesien virtausta ja lämpötilaa tarkkaillaan lämpötila- ja virtausmittauksilla. (Gramberger & Knapp 2001)

### **2.3.3 Panosmateriaalit**

Terässulaton linja 2:n tuotanto voidaan jakaa ruostumattomiin teräksiin ja haponkestäviin ruostumattomiin teräksiin. Nämä kaksi eroavat toisistaan käytettävän panosmateriaalin osalta. Kierrätysteräs muodostaa valtaosan panoksesta, ja kierrätysteräkset voidaan jakaa neljään pääryhmään: haponkestävä ostokierrätysteräs, ruostumaton ostokierrätysteräs, tehtaan sisäisessä kierrossa sulatolle palautuvat haponkestävät ja ruostumattomat kierrätysmateriaalit. Joskus sulatuksissa käytetään myös seostamatonta kierrätysterästä. Koska lämmönsiirto on romussa rajoittava tekijä, suositaan romua, joka on tilavuuspainoltaan  $0,5 \text{ t/m}^3 - 1,1 \text{ t/m}^3$ . Ruostumattoman teräksen valmistuksessa käytetyin seosaine on ferrokromi. Muita käytettyjä seosaineita ovat ferronikkeli, nikkelikatodit ja molybdeenioksidit. Kuonanmuodostajina prosessissa käytetään kalkkimursketta, vuoraustiilimursketta ja dolomiittikalkkia. Koska prosessin aikana kuonaan pelkistyy kromia, se saatetaan takaisin teräsfaasiin pelkistimien avulla. Uuniin panostetaan piipitoisia pelkistimiä, kuten ferropiitä. Myös hiili pystyy estämään kromin pelkistymisen. Kun panosmateriaalin hiili palaa prosessissa syntyy pelkistävä atmosfääri,



jonka seurauksena piin palaminen hidastuu. Kun saavutetaan yli 1480 °C lämpötila ja riittävän korkea hiilipitoisuus, pystyy hiili estämään kromin hapettumisen. Taulukossa 1 on esitetty yksi esimerkki siitä, paljonko raaka-aineita käytetään tuotettua terästonnia kohden. Koska panoksen mukana uuniin päätyy myös ei-toivottuja materiaaleja, kuten maata, vettä ja jäätä, ne on lisätty taulukkoon 1. (Gramberger & Knapp 2001, Hyttinen 2013)

Taulukko 1. Valokaariuunin panos tuotettua terästonnia kohde (mukaillen Karassaari 2008).

Materiaali	Massa (kg/t)
Romut ja seosaineet	1069
Kuonanmuodostajat	43
Koksi	3,6
Elektrodien kulutus	n. 2-4
Vuorauksen kulutus	1
Pöly	15
Ei-toivotut materiaalit, kuten vesi ja jää	X


## 2.4 Prosessivaiheet

### 2.4.1 Panostus

Itse valokaariuuniprosessin ensimmäinen vaihe on panostus. Raaka-ainepihalla kasatut romukorit panostetaan uuniin nosturin avulla. Prosessissa voidaan käyttää joko yhtä tai useampaa romukoria. Jos romukoreja panostetaan enemmän kuin yksi, joudutaan prosessi keskeyttämään panostuksen ajaksi. Erityisesti talvella, jos romukori panostetaan uuniin, kun uunissa on jo sulaa, tulee se kuivata vedestä ja lumesta johtuvien räjähdysten estämiseksi. Panostuksen aikana uunin holvi ja elektrodilaitteisto ajetaan syrjään ja romukori ajetaan uunin päälle, minkä jälkeen sen pohja aukaistaan. Uunin pohjan säästämiseksi romukori lastataan niin, että pohjalle tulee ”kevyttä” romua korin aukeamisen helpottamiseksi. Prosessin aikana on myös mahdollista lisätä siiloista pelkistimiä, seosaineita ja kuonanmuodostajia. (Gramberger & Knapp 2001, Hyttinen 2013)

### 2.4.2 Sulatus


Sulatuksen vaiheet voidaan jakaa sytytykseen, porautumiseen, sulatukseen, lämmitykseen ja kaatoon. Kuvassa 3 on esitetty elektrodien liikkeitä kahden korin sulatuksen aikana ajan funktiona. (Karassaari 2008)



Kuva 3. Elektrodien liikkeitä ajan funktiona (mukaiillen Hyttinen 2013).

Sulatuksen alussa elektrodit ajetaan lähelle romua ja kytketään päälle sytytysjännite. Valokaaren syntymisen jälkeen elektrodeilla porataan kolot panosmateriaaliin, jänniteporrasta nostetaan ja uunia ajetaan täydellä teholla mahdollisimman pitkään. Elektrodien ollessa porautuneina romun keskelle romu suojaa uunin rakennetta valokaarilta. Panosmateriaali sulaa ensimmäiseksi elektrodien läheisyydestä, ja sulaminen etenee alhaalta ylöspäin ja kohti uunin reunoja. Uunin kylmempiä alueita lämmitetään sulatuksen alussa happi-kaasupolttimien avulla sulatuksen nopeuttamiseksi. Jos käytetään kahden tai useamman romukorin ajopraktiikkaa, uuniin panostetaan romukori, kun romua on sulanut tarpeeksi ja uunin on vapautunut riittävästi tilaa. Sulamäärän kasvaessa jänniteporrasta lasketaan asteittain uunin seinämien suojaamiseksi lämpörasitukselta. Sulaa lämmitetään pienellä jänniteportaalla ja lyhyellä valokaarella, jolloin mahdollisimman suuri osa sähköenergiasta siirtyy sulaan. Kuvassa 4 on esitetty tarkemmin elektrodien sijaintia suhteessa romuun sulatuksen aikana.

Lämmönnostovaihetta tehostetaan puhaltamalla happi-kaasupolttimilta happea sulaan, jolloin vapautuu kemiallista energiaa, jolla saadaan korvattua sähköenergiaa. Sulan kemiallisen koostumuksen vuoksi happi reagoi pääasiassa piin kanssa. Kun haluttu lämpötila sulalle on saavutettu, se kaadetaan siirtosenkkaan. (Karassaari 2008)



Kuva 4. Sulatuksen prosessivaiheet (mukaillen Oulun yliopisto 2019b, © Luxmet Oy).

## 2.5 Sulatuksen aikana tapahtuvat kemialliset reaktiot


Valokaariuuniprosessissa syntyvä kemiallinen energia on peräisin panoksen metallisten komponenttien hapettumisesta ja hiilen palamisesta. Näiden komponenttien ja hiilen kanssa reagoiva happi syötetään prosessiin happi-kaasupolttimien avulla, vuotoilmana ja romussa esiintyvänä oksideina. VKU2:lla vuotoilmaa pääsee uuniin kaatoaukon ja holvin raosta sekä elektrodien rei'istä. Kun happi reagoi metallisten alkuaineiden kanssa, syntyy oksideja, joiden ominaistiheys on matalampi kuin metallien eli ne kelluvat sulan teräksen pinnalla. Koska valokaariuuniprosessissa metallisiin alkuaineisiin vaikutetaan hapella, muodostuvat ongelmaksi metallit, joiden affiniteetti happeen on alhaisempi kuin hapen affiniteetti rautaan. Tällaisia vaikeita komponentteja ovat jo aiemmin mainitut kupari, nikkeli ja molybdeeni. Koska prosessin aikana osa arvokkaasta kromista hapettuu kuonafaasiin, se pelkistetään takaisin teräkseen ferropiin avulla. Kuonan kromioksidipitoisuus ennen pelkistystä on 20-25 % ja pelkistyksen jälkeen 3-5 %. Samalla kun kromi pelkistetään, myös rauta pelkistyy kuonafaasista takaisin teräsfaasiin. Taulukossa 2 on esitetty VKU2:n pääreaktiot eli hiilen palaminen, metallien hapettuminen ja kromin pelkistys piillä. Kaikki esitetyt pääreaktiot ovat eksotermisiä eli niiden tapahtuessa vapautuu energiaa, joka korvaa sähköenergian tarvetta valokaariuunissa. Kuten aiemmin mainittu, myös fosfori tuottaa ongelmia ruostumatonta terästä valmistettaessa. Kuonan emäksisyyden ja matalan happiaktiivisuuden vuoksi fosforin poistaminen teräksestä on mahdotonta, minkä seurauksena tulee rajoittaa

panosmateriaalien käyttö vain matalafosforisiin materiaaleihin. Myös rikin poisto on kuonan koostumuksesta johtuen mahdotonta. (Gramberger & Knapp 2001)

Taulukko 2. VKU2:n pääreaktiot ja niiden reaktioentalpiat. (mukaillen Gramberger & Knapp 2001).

Pääreaktio- kaavat	Entalpia
$2 \text{ C} + \text{O}_2 = 2 \text{ CO}$	-2,85 kWh/kg C
$2 \text{ CO} + \text{O}_2 = 2 \text{ CO}_2$	-6,55 kWh/kg C
$\text{Si} + \text{O}_2 = \text{SiO}_2$	-8,96 kWh/kg Si
$4 \text{ Al} + 3 \text{ O}_2 = 2 \text{ Al}_2\text{O}_3$	-8,63 kWh/kg Al
$2 \text{ Mn} + \text{O}_2 = 2 \text{ MnO}$	-1,95 kWh/kg Mn
$2 \text{ Fe} + \text{O}_2 = 2 \text{ FeO}$	-1,32 kWh/kg Fe

Kuvassa 5 on esitetty valokaariuuniin panostettavien komponenttien jakautuminen eri ulostulosvirtoihin. Pölyt poistuvat uunista pääasiassa savukaasujen mukana savukaasulaitokselle. Kuona ja teräs kaadetaan uunista siirtosenkkaan, jossa kuona nousee kevyempänä teräksen pinnalle. Kuona kaadetaan senkasta kuonapataan. Kuvassa on myös määritelty eri komponenttien jakautuminen eri ulostulovirtoihin. Voidaan huomioda, että arvokasta kromia esiintyy kaikissa ulostulovirroissa. Tämän takia prosessia tulisi operoida niin, että mahdollisimman suuri osa kromista päätyisi teräkseen. Kuvasta nähdään myös, että vaikeat materiaalit, kuten kupari, esiintyvät ainoastaan teräksessä.



Kuva 5. Valokaariuunissa esiintyvien alkuaineiden jakautuminen ulostuloihin (mukaillen Hasa 2016).

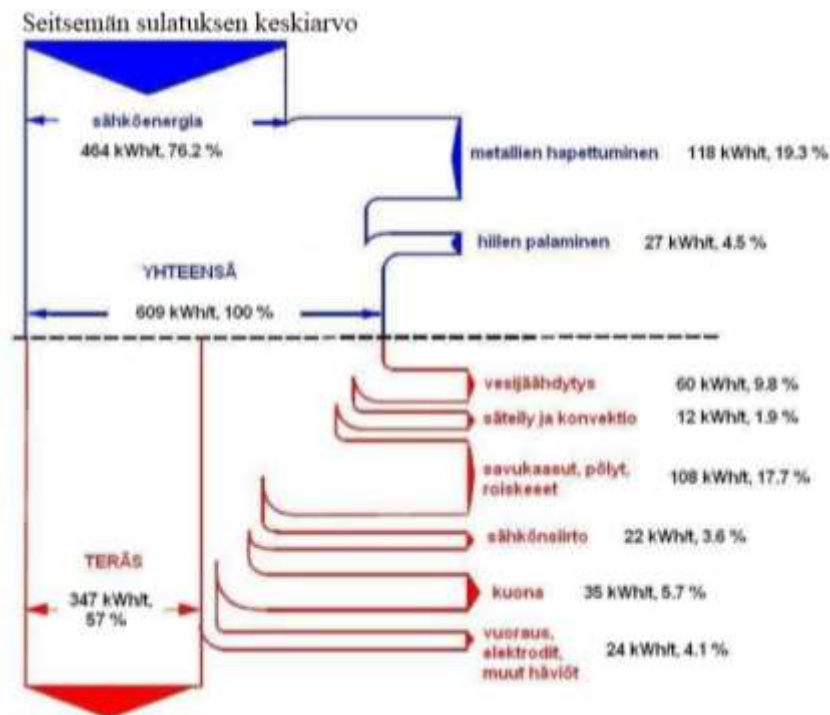
## 2.6 Kuona

Kuonan tehtävänä valokaariuuniprosessissa on suojata uunin vuorausta ja kerätä yhteen komponentit, jotka eivät päädy teräsfaasiin. Kuonan avulla voidaan myös ohjata komponenttien jakautumista kuona- ja teräsfaaseihin ja suojata terästä hapettumiselta. Kun kuona on teräksen pinnalla, se suojaa metallisia komponentteja teräksessä. Erityisesti ruostumatonta terästä valmistettaessa tämä suojaa kromia hapettumiselta. Kuonan optisen emäksisyyden halutaan olevan noin 1,5. Tällöin kuonan vuorausta kuluttava vaikutus pienenee ja kuonan kuohuminen mahdollistuu. Kuonan kuohuminen on haluttu ilmiö valokaariuuniprosessissa sillä se parantaa energiatehokkuutta ja suojaa vuorausta. Kuohuva kuona peittää valokaarta pidemmältä matkalta kuin kuohumaton, jolloin lämpösäteily kohdistuu teräkseen ja kuonaan uunin seinämien sijaan. Tällöin on mahdollista käyttää pidempää valokaarta, jolloin sulatus tehostuu ja sulatusaika lyhenee. (Kunelius 2010)

Kuitenkin kuonan kuohuttaminen ruostumattoman teräksen valmistuksessa on hyvin vaikeaa, koska kromioksidit muodostavat kiintoainepartikkeleita. Syntyneet kiintoainepartikkelit heikentävät kuonan kaasunpidätyskykyä, minkä seurauksena kaasu virtaa kuonan läpi muodostamatta kuplia. Kuitenkin Reichelin et al. (2008) tutkimuksessa saatiin tehostettua ruostumattoman teräksen kuonan kuohumista ja pidennettyä valokaarien pituutta, minkä seurauksena lämpötilagradiendi kasvoi. Tämä saatiin aikaan käyttämällä erikoisvalmisteisia brikettejä, joiden avulla tehostettiin hiilimonoksidin ja hiilidioksidin muodostumista teräksen ja kuonan rajapinnalla. (Reichel 2008)

### 3 VALOKAARIUUNIN ENERGIATASE

Kehittäessä ja optimoidessa valokaariuuniprosesseja aine- ja energiataseet ovat perustana käytetyille työkaluille. Energiatase perustuu termodynamiikan ensimmäisen pääsääntöön eli energian häviämättömyyden lakiin. Sen mukaan energia voi esiintyä eri muodossa ja muuttua toiseen muotoon, mutta energiaa ei voi syntyä eikä hävitä itsestään. Kun termodynamiikan ensimmäistä pääsääntöä käytetään tasetarkastelujen pohjana, tulee muodostaa systeemi, jota tarkastellaan. Systeemit voidaan jakaa avoimiin ja suljettuihin, joista avoimella systeemillä on mahdollista vaihtaa ainetta ja energiaa ympäristön kanssa. Suljettu systeemi pystyy vaikuttamaan ympäristöön vain energianvaihdon välityksellä. Jos systeemi ei ole vuorovaikutuksessa ympäristön kanssa aine- tai energiansiirron välityksellä, puhutaan eristetystä systeemistä. Tarkastelussa ympäristö on systeemiä ympäröivä alue ja systeemi tarkasti rajapinnalla erotettu alue ympäristöstä. Systeemiä voidaan määrittellä myös vakio-oletuksien kautta. Systeemin lämpötila, paine tai tilavuus voidaan määrittää vakioksi. Tässä luvussa esitetyt aine- ja energiataseet ja niiden kaavat perustuvat pääasiassa Pfeiferin ja Kirschenin 2000-luvun alussa tekemiin julkaisuihin (Kirschen et al. 2002, Pfeifer et al. 2002, Pfeifer et al. 2005) Heidän julkaisuissaan luodut mallit on kehitetty todellisten valokaariuunien pohjalta. Kuvassa 6 on Karassaaren (2008) luoma energiatase Outokummun Tornion tehtaan VKU2:lle. (Kirschen et al. 2002)




Kuva 6. VKU2 energiatase (mukaiillen Karassaari 2008).

### 3.1 Energiatase

#### 3.1.1 Valokaariuunin tasealue

Laadittaessa valokaariuunille energiatasetta tulee rajata selvästi määritetty tasealue. Valokaariuunin tasealuetta kuvataan avoimena systeeminä, jonka läpi energia ja massa virtaavat. Kuvassa 7 on tasealueeseen sisällytetty valokaariuunin lisäksi happilanssi, kaasupolttimet, jälkipolttimet sekä savukaasun poiston alkukäyrä. Kuvassa ei ole otettu huomioon muuntajaa, sähkönsiirtolaitteistoa, savukaasujen puhdistusjärjestelmää eikä romujen esikuivausta. Tasealue voitaisiin luoda myös ottamaan huomioon jokin tietty osa valokaariuunista, kuten savukaasujärjestelmä kokonaisuudessaan. Tasealuetta voitaisiin myös laajentaa niin, että se ottaisi huomioon esimerkiksi koko terässulaton. (Pfeifer et al. 2002)




Kuva 7. Valokaariuunin tasealue ja termit (mukaillen Pfeifer et al. 2005).

#### 3.1.2 Valokaariuunin ainetase

Ainetaseen avulla on tarkoitus määrittää systeemissä, eli tässä tapauksessa valokaariuunissa, tapahtuvat metallurgiset reaktiot, systeemiin virtaavan ilman määrä ja valokaariuunista poistuvien savukaasujen määrä. Ainetaseen luomiseksi tarvitaan myös muita helposti määritettäviä arvoja, kuten systeemiin syötettyjen metallien määrä, elektrodien kuluminen, polttoaineiden syöte, kuonanmuodostajien määrä, metallien lämpösisältö ja kuonan lämpösisältö. Näiden termien määrittämiseksi on erityisen tärkeää analysoida uunista poistuvia virtoja, kuten savukaasujen määrä, koostumus ja lämpötila.

Kuvassa 8 on esitetty valokaariuunin ainetase tuotettua terästönä kohden yhdestä 100 tonnin uunista 31 sulatuksen keskiarvona. Esitetyt tulokset perustuvat hiilen ainetaseeseen, joka on selvitetty savukaasujen avulla, typen ainetaseeseen, joka perustuu vuotoilman määrään uunissa sekä kalsiumoksidin ainetaseeseen, jonka avulla voidaan selvittää kuonan massa. (Pfeifer et al. 2002)



Kuva 8. Valokaariuunin ainetase (mukaillen Pfeifer et al. 2002).

### 3.1.3 Energiataseen muodostaminen valokaariuunille

Valokaariuunille on mahdollista johtaa energiatase termodynamiikan ensimmäisen pääsäännön yhtälön (1) mukaan.

$$\text{Energia sisään} = \text{Energia ulos} + \text{Energiahäviöt} \quad (1)$$


Yhtälön (1) avulla on mahdollista johtaa energiataseyhtälö (2) valokaariuunille. Energiatase kuvaa valokaariuunin meneviä ja lähteviä energiavirtoja. Tornion terästehtaalla ei ole käytössä sulapanostus-praktiikkaa. Täten yhtälössä (2) oleva termi  $E_{HM}$  ei ole olennainen Tornion valokaariuunien tarkastelussa. (Pfeifer et al. 2002)

$$E_{total} = \eta_{el} \cdot E_{el} + \sum E_{Chem,i} + E_{HM} = E_{Steel} + E_{Slag} + E_{Dust} + E_{Offgas} + E_{Rad} + E_{Cool} + E_{Others} \quad (2)$$



missä  $E_{\text{total}}$  on valokaariuunin käyttämän kokonaisenergia [kWh],  
 $\eta$  on korkeajännitejärjestelmän hyötysuhde,  
 $E_{\text{el}}$  on sähköenergia [kWh],  
 $\Sigma E_{\text{Chem}}$  on kemiallisten reaktioiden lämpösisällön summa [kWh],  
 $E_{\text{HM}}$  on panostettavan sulan teräksen lämpösisältö [kWh],  
 $E_{\text{Steel}}$  on teräksen lämpösisältö [kWh],  
 $E_{\text{Slag}}$  on kuonan lämpösisältö [kWh],  
 $E_{\text{Dust}}$  on pölyjen lämpösisältö [kWh],  
 $E_{\text{Offgas}}$  on savukaasujen lämpösisältö [kWh],  
 $E_{\text{Rad}}$  on systeemistä säteilemällä poistuva lämpösisältö [kWh],  
 $E_{\text{Cool}}$  on uunin jäähdytysjärjestelmään siirtyvä lämpösisältö [kWh] ja  
 $E_{\text{Others}}$  on muut määrittelemättömät häviöt [kWh].

Kuvassa 9 on esitetty valokaariuunille energiatase, josta nähdään, että suurin osa systeemiin menevästä energiasta on sähköenergiaa. Sisään menevästä energiasta 65 % on peräisin sähköenergiasta, 30 % eksotermisistä reaktioista ja 5 % happi-kaasupolttimista. Kokonaisenergiasta 57 % kuluu teräksen sulatukseen ja 10 % kuonansulatukseen. Loput energiasta poistuu valokaarista erilaisina lämpöhäviöinä, kuten savukaasujen mukana 21 %, uunin jäähdytyksen seurauksena 10 % ja loput 2 % muina määrittelemättöminä häviöinä. (Wilson et al. 1998)



Kuva 9. Valokaariuunin energiatase (mukaiillen Wilson et al. 1998).

## 3.2 Prosessin kokonaisenergian kulutukseen vaikuttavat tekijät

Kun tarkastellaan valokaariuunia ja erityisesti, kun halutaan kehittää prosessin tehokkuutta, on tärkeää tarkastella eri tekijöiden hyötysuhteita. Jos saadaan selville, että jokin valokaariuunin hyötysuhteista eroaa merkittävästi kirjallisuudessa esitetyistä arvoista, voi olla ajankohtaista kehittää tätä osaa prosessista.

### 3.2.1 Valokaariuunin panoksen vaikutus kokonaisenergian kulutukseen

Mitä suurempi panospaino on, sitä enemmän sen sulattamiseen tarvitaan energiaa. Suurista panospainoista myös seuraa usein tarve käyttää enemmän kuin yhtä romukoria, mistä syntyy pidempiä sulatusaikoja. Suuremmasta panospainosta on myös hyötyä, koska on enemmän romua ja kuonaa, jotka suojaavat uunin seinämiä. Myös panosmateriaalin koko ja tiheys vaikuttavat energian tarpeeseen siten, että pienen kappalekoon omaava materiaali mahtuu tiiviimmin romukoriin ja koreja tarvitaan vähemmän. Pienemmän kappalekoon omaava romu myös sulaa tehostuneen lämmönsiirron seurauksena nopeammin kuin suurikokoinen romu. (Kunelis 2010, Pfeifer et al. 2005)

Pfeifer et al. (2005) regressiomallien avulla teoreettiset entalpiat romun ja kuonanmuodostajien sulatukselle. Jo ennen tulosten tarkastelua on otettava huomioon, että julkaisussa metallien saannin on oletettu olevan 100 %, mikä eroaa todellisuudesta. Tämän seurauksena todellinen energiantarve tuotettua tonnia kohden on suurempi kuin mallinnettu. Nämä entalpiat on määritelty teräksen lämmittämiseen 20 °C:sta 1600 °C:een. Tällöin matalaseosteisen hiiliteräksen entalpien ( $\Delta h_{\text{Steel}}$ ) on määritetty olevan 361 kWh/t. Samassa julkaisussa on määritelty korkeaseosteisen Cr-Ni-ruostumattoman teräksen entalpiaksi ( $\Delta h_{\text{Steel}}$ ) 372 kWh/t. On huomioitavaa, ettei näihin arvoihin ole otettu huomioon myöskään hyötysuhteiden vaikutusta. Kuvassa 8 on esitetty, että tuotettua terästönna kohden valokaariuuniin panostetaan 25-50 kg kalkkia tai kalkin ja dolomiitin seosta. Lämmitettäessä puhtaita aineita 20 °C:sta 1600 °C:een tarvittava entalpia kalkille ( $\Delta h_{\text{CaO}}$ ) on 416 kWh/t<sub>CaO</sub> ja dolomiitille ( $\Delta h_{\text{MgO}}$ ) 550 kWh/t<sub>MgO</sub>. Käytettäessä dolomiitin ja kalkin seosta suhteessa 5 CaO : 1 MgO on määritetty entalpiaksi 1600 °C:ssa ( $\Delta h_{\text{CaO/MgO}}$ ) 438 kWh/t<sub>CaO/MgO</sub>. Myöskään näihin arvoihin ei ole otettu huomioon hyötysuhteiden vaikutusta energian tarpeeseen. (Pfeifer et al. 2005)

### 3.2.2 Hyötysuhteiden vaikutus kokonaisenergian kulutukseen

Valokaariuunin energiatehokkuutta voidaan tarkastella teräkseen sitoutuneen energian avulla. Yhtälössä (3) on esitetty kaava, jonka avulla voidaan määrittää valokaariuunin hyötysuhde. Jossakin tapauksissa myös kuonaan sitoutunut energia määritellään hyödylliseksi, jolloin saadaan hyötysuhteen kaavaksi yhtälö (4). Tästä syystä kirjallisuutta ja valokaariuuneja tarkastellessa on tärkeää ottaa huomioon, mitä tapaa on käytetty hyötysuhteen määrittämisessä. (Pfeifer et al. 2002)

$$\eta_{EAF} = \frac{\text{Entalpy steel}}{\text{Total energy input}} \quad (3)$$

$$\eta_{EAF} = \frac{\text{Entalpy steel+slag}}{\text{Total energy input}} \quad (4)$$

Valokaariuuniin syötettyjen energialähteiden energian johtuminen panokseen poikkeaa ideaalista. Tästä syystä kirjallisuudessa on esitetty hyötysuhteita valokaariuunin kokonaisenergian tarpeelle ja yksittäisille energian lähteille. Näitä arvoja on esitetty taulukossa 3. Taulukossa ei ole erikseen esitetty hyötysuhdetta kemialliselle energialle, mutta tämä voidaan arvioida happilanssille, happi-kaasupolttimien ja jälkipalamisen hyötysuhteen avulla. Taulukossa 4 on esitetty hyötysuhteita eri valokaariuuneille. On huomioitavaa kuinka suuria, jopa 10 % eroja, valokaariuunien väillä esiintyy. Erityisen suuri ero hyötysuhteissa on ferriittisen ja austeniittisen teräksen valmistuksessa 150 tonnia valokaariuunissa. Taulukossa 4 esitetyt hyötysuhteet on laskettu yhtälön (4) mukaan. (Pfeifer et al. 2002, Pfeifer et al. 2005)

Taulukko 3. Hyötysuhteita eri energialähteille valokaariuunissa (Pfeifer et al. 2005).

Energy source	Efficiency factor of energy transfer	Abbreviation	[%]	Source
Total energy	Efficiency factor	$\eta_{N,EAF}$	50 - 67	[2] [17]
Electric energy	Efficiency factor of high current system	$\eta_{el}$	90 - 95	[17]
	Thermal efficiency factor of electric arc	$\eta_{arc}$	36 - 93	[29]
	Total efficiency factor of electric energy	$\eta_{el}\eta_{arc}$	60 - 80	
Oxygen lances	Efficiency factor of oxygen injection	$\eta_L$	70 - 80	[13]
Oxy-fuel burner	Efficiency factor of oxy-fuel burners	$\eta_G$	50 - 60	[19]
Post-combustion of off-gas in EAF	Efficiency factor of post-combustion	$\eta_{PC}$	30 - 50	[13] [22]


Taulukko 4. Eri valokaariuunien hyötysuhteita (Preifer et al. 2002).

	year	total energy input [kWh/t]	electric energy input [kWh/t]	steel/slag energy [kWh/t]	$\eta_{EAF}$ %	
100t-furnace, structural steel	1980	(798)	(541)	(503)	(53.0)	[5]
140t-furnace,	2001	773	497	442	57.2	
120t-furnace, stainless steel	1989	704	487	443	59.2	[9]
150t-furnace, ferritic steel	2001	758	477	449	59.2	[8]
150t-furnace, austenitic steel	2002	807	510	401	49.7	
60t-furnace, scrap preheating	1990	729	427	429	58.8	[10]
conventional furnace	1998	680	400	440	54.7	[11]
100t-furnace	1999	810	393	434	53.5	
average		752	456	434	58.0	

### 3.2.3 Kaatolämpötilan vaikutus valokaariuunin energiankulutukseen

Kaatolämpötila vaikuttaa merkittävästi valokaariuunin sähköenergiankulutukseen. Teollisuudessa kaatolämpötilat vaihtelevat 1550 °C:sta 1750 °C:een. Kuvassa 10 on esitetty matalaseosteiselle hiiliteräkselle ja korkeaseosteiselle Cr-Ni-ruostumattomalle teräkselle entalpiat kaatolämpötilan funktiona. Kummankin teräslajin kulmakerroin on lähes identtinen  $\Delta h(T_A)/\Delta T_A = 0,23 \text{ kWh/Kt}$ . Hyötysuhteen  $\eta_{el} \cdot \eta_{arc}$  ollessa 60-80 % energiantarve kaatolämpötilan funktiona voidaan esittää yhtälön (5) avulla. (Pfeifer et al. 2002, Pfeifer et al. 2005)

$$\Delta e_{el,T_A} = \frac{1}{\eta_{el} \eta_{arc}} \cdot \frac{\Delta h(T_A)}{\Delta T_A} = 0,29 - 0,38 \text{ kWh/Kt} \quad (5)$$



Kuva 10. Teräksen entalpia kaatolämpötilan funktiona (mukaillen Pfeifer et al. 2005).

### 3.2.4 Sulatuksen keston vaikutus energiantarpeeseen

Kaadosta kaatoon ajalla  $\Delta t_c = t_s + t_n$  on vaikutusta kaikkiin valokaariuuniprosessin ajasta riippuvaisiin energiahäviöihin, joita ovat häviöt savukaasuihin, pölyyn, uuniin jäähdytyskiertoon ja lämpösäteilyyn. Energiantarvetta kaadosta kaatoon aikana vähentävät prosessissa syntyvä kemiallinen energia ja panostettava sula. Kaadosta kaatoon -ajan vaikutus sähköenergian tarpeeseen voidaan määrittää yhtälön (6) avulla. Neljälle eri uunille, joiden panoskoko vaihteli välillä 70-150 tonnia, on määritetty energian tarpeeksi kaadosta kaatoon-aikana  $\Delta e_{el,\Delta t}/\Delta t_c = 0,8 - 1,3 \text{ kWh/t min.}$  Tämän energiahukan on todettu vaihtelevan suuresti riippuen, missä vaiheessa sulatus on. Sulatuksen alussa energiahukka on huomattavasti pienempi 0,4 kWh/t-min kuin sulatuksen lopussa 1,7 kWh/t-min. (Pfeifer et al. 2002, Pfeifer et al. 2005)

$$\frac{de_{el}(t)}{dt} = \frac{e_{Dust}(t) + e_{Offgas}(t) + e_{Rad}(t) + e_{Cool}(t) - e_{HM}(t) - \Sigma e_{Chem,i}(t)}{\eta_{el}} \quad (6)$$

missä  $t_c$  on kaadosta kaatoon-aika [min],

$t_s$  on teho päällä aika [min] ja

$t_n$  on teho pois aika [min].

## 3.3 Kemiallinen energia

Jatkuvasti kallistuvan sähköenergian hinnan vuoksi teräksen valmistajat ovat kehittäneet tapoja korvata sähköenergiaa valokaariuunissa (Kirschen et al. 2017). Kemiallinen energia uunissa syntyy, kun panosmateriaalit reagoivat uuniatmosfääriin kanssa. Kemiallisen energian käytön lisääntymisestä valokaariuuniprosessissa on pääasiassa vastannut happilanssaus ja polttimien käyttö.

### 3.3.1 Happi-kaasupolttimien käyttö valokaariuunissa

Happi-kaasupolttimia asennetaan valokaariuuneihin tehostamaan niiden sulatustehoa ja erityisesti lämmittämään kylmempiä alueita uunista, jotta niiden lämpötilasymmetrisyys paranisi. Yleisesti polttimet ovat päällä ensimmäiset 5-15 minuuttia sulatuksen aloituksesta, koska tällöin lämmönsiirto polttimilta panokseen on tehokkainta. Lämpötilan kasvaessa lämmönsiirron tehokkuus huononee merkittävästi. Saatava kemiallinen energia tavallisesti käytettävissä polttoaineissa on yleisesti  $h_{u,G} = 9,3 -$

$10,7 \text{ kWh/m}^3$ . Taulukosta 3 nähdään happi-kaasupolttimien hyötysuhteen  $\eta_g$  olevan 50-60 %. Happi-kaasupolttimien käytön vaikutus valokaariuunin sähköenergian tarpeeseen nähdään yhtälöstä (7). Happi-kaasupolttimia voidaan myös hyödyntää jälkipoltossa, kun niiden syötteen happipitoisuutta nostetaan. (Pfeifer et al. 2002, Pfeifer et al. 2005)

$$\Delta e_{el,G} = \frac{\eta_G \cdot h_{u,G}}{\eta_{el} \cdot \eta_{arc}} = -6,9 - (-11,5 \text{ kWh/m}_G^3) \quad (7)$$

### 3.3.2 Happilanssaus

Lanssilla tai happi-kaasupolttimien kautta voidaan syöttää lisähappea valokaariuuniin. Happea virtaa systeemiin myös vuotoilmana tai sitä voidaan syöttää suuttimilla lisää. Happi reagoi uunissa seosaineiden, kuten P, Al ja Si, kanssa ja ne hapettuvat lähes kokonaan prosessissa. Osittain prosessissa hapettuvat myös C, Fe, Mn, Cr ja Mo, kun hapen osapaine kasvaa systeemissä. Kemiallisissa reaktioissa syntyvään energiaan vaikuttavat systeemin syöte ja ulostulot. Teollisuudessa olevissa valokaariuuneissa hapetusreaktioista saatava energia vaihtelee välillä 50-300 kWh/t. Taulukossa 5 on esitetty yleisimmät eksotermiset hapettumisreaktiot ja niihin liittyvät entalpian muutokset. Systeemiin syötettävän hapen reaktioissa muodostuvan energian  $\Delta h$  avulla voidaan laskea yhtälöä (8) käyttäen, paljonko hapettumisreaktioiden kemiallisella energialla voidaan korvata sähköenergiaa systeemissä. Taulukosta 3 saadaan hapensyötön hyötysuhteeksi  $\eta_L = 70 - 80 \%$ . (Pfeifer et al. 2002, Pfeifer et al. 2005)

$$\Delta e_{el,L} = \frac{\eta_L \cdot \Delta h_L}{\eta_{el} \cdot \eta_{arc}} = \text{kWh/m}^3 \quad (8)$$

Taulukko 5. Eksotermiset hapettumisreaktiot ja niiden energiasisällöt valokaariuunissa. (Pfeifer et al. 2005)

Chemical reactions in the steel melt					Reaction enthalpy	
Si	+	O <sub>2</sub>	→	SiO <sub>2</sub>	- 8.94 kWh/kg <sub>Si</sub>	- 11.20 kWh/m <sup>3</sup> O <sub>2</sub>
Mn	+	0.5 O <sub>2</sub>	→	MnO	- 1.93 kWh/kg <sub>Mn</sub>	- 9.48 kWh/m <sup>3</sup> O <sub>2</sub>
2 Cr	+	1.5 O <sub>2</sub>	→	Cr <sub>2</sub> O <sub>3</sub>	- 3.05 kWh/kg <sub>Cr</sub>	- 9.42 kWh/m <sup>3</sup> O <sub>2</sub>
2 Fe	+	1.5 O <sub>2</sub>	→	Fe <sub>2</sub> O <sub>3</sub>	- 2.05 kWh/kg <sub>Fe</sub>	- 6.80 kWh/m <sup>3</sup> O <sub>2</sub>
Fe	+	0.5 O <sub>2</sub>	→	FeO	- 1.32 kWh/kg <sub>Fe</sub>	- 6.58 kWh/m <sup>3</sup> O <sub>2</sub>
C	+	0.5 O <sub>2</sub>	→	CO	- 2.55 kWh/kg <sub>C</sub>	- 2.73 kWh/m <sup>3</sup> O <sub>2</sub>
2 Al	+	1.5 O <sub>2</sub>	→	Al <sub>2</sub> O <sub>3</sub>	- 5.29 kWh/kg <sub>Al</sub>	- 13.84 kWh/m <sup>3</sup> O <sub>2</sub>
Mo	+	O <sub>2</sub>	→	MoO <sub>2</sub>	- 1.70 kWh/kg <sub>Mo</sub>	- 7.29 kWh/m <sup>3</sup> O <sub>2</sub>
S	+	O <sub>2</sub>	→	SO <sub>2</sub>	- 2.75 kWh/kg <sub>S</sub>	- 3.94 kWh/m <sup>3</sup> O <sub>2</sub>
2 P	+	2.5 O <sub>2</sub>	→	P <sub>2</sub> O <sub>5</sub>	- 5.54 kWh/kg <sub>P</sub>	- 8.58 kWh/m <sup>3</sup> O <sub>2</sub>
Chemical reactions in the gas phase					Reaction enthalpy	
C	+	O <sub>2</sub>	→	CO <sub>2</sub>	- 9.10 kWh/kg <sub>C</sub>	- 4.88 kWh/m <sup>3</sup> O <sub>2</sub>
CO	+	0.5 O <sub>2</sub>	→	CO <sub>2</sub>		- 7.01 kWh/m <sup>3</sup> O <sub>2</sub>
H <sub>2</sub>	+	0.5 O <sub>2</sub>	→	H <sub>2</sub> O		- 5.99 kWh/m <sup>3</sup> O <sub>2</sub>

### 3.3.3 Jälkipoltosta syntyvä kemiallinen energia

Jälkipolton tarkoituksena valokaariuunissa on polttaa prosessissa syntyvät CO- ja H<sub>2</sub>-kaasut. Jos näitä kaasuja esiintyy prosessissa, ne eivät ole palaneet täydellisesti ja energiaa hukataan. Kaavoissa (9) ja (10) on esitetty jälkipalamisen aikana tapahtuvat reaktiot. Jälkipalaminen siis toteutetaan syöttämällä uuniin lisää happea. (Pfeifer et al. 2005)



Taulukosta 5 saadaan CO-reaktiolle entalpiaksi  $\Delta_r h_{CO} = -7,01 \text{ kWh/m}^3 O_2$  ja H<sub>2</sub>-reaktiolle entalpiaksi  $\Delta_r h_{H_2} = -5,99 \text{ kWh/m}^3 O_2$ . Vapautuva energia kaasufaasista, jonka koostumus on 25 % CO ja 10 % H<sub>2</sub>, on esitetty kaavassa (11). Taulukossa 3 jälkipolton hyötysuhteen  $\eta_{PC}$  on esitetty olevan 30-50 %. (Pfeifer et al. 2005)

$$\Delta_r h_{PC} = \frac{25 \cdot \Delta_r h_{CO} + 10 \cdot \Delta_r h_{H_2}}{35} = -6,8 \text{ kWh/m}^3 O_2 \quad (11)$$

### 3.4 Häviöt

Kuten aiemmin mainittiin, noin 57 % valokaariuuniin syötettävästä energiasta sitoutuu itse teräkseen. Loppuenergia poistuu uunista erilaisten häviöiden seurauksena sitoutuneena muuhun kuin teräkseen. Uunien energiatehokkuus voi myös laskea epäoptimaalisten raaka-aineiden seurauksena. Tästä syystä hyvälaatuisen romun hankkiminen prosessia varten on erityisen tärkeää prosessin tehokkuuden ja lopputuloksen kannalta. Kuitenkin hyvälaatuinen romu on kalliimpaa ja romuksi todellisuudessa valikoituu mahdollisimman optimaalinen romu, laadun ja hinnan kannalta.

#### 3.4.1 Ei-toivotut materiaalit panoksessa

Jos kierrätysteräs sisältää paljon ei-rautametalreja, oksideja, rasvaa, öljyä, vettä tai muita epäpuhtauksia, kuten puuta, tarvittavan kokonaisenergian määrä kasvaa prosessissa. Tarvittava energia näiden ei-toivottujen materiaalien sulatukseen voidaan määrittää yhtälön (12) avulla. (Pfeifer et al. 2005)

$$\Delta h_E = \int_{t_c} \sum_i m_{Dust,met,i} \Delta h_{Dust,met,i}(T) dt + \Sigma m_{Slag,met,i} \Delta h_{Slag,met,i}(T) + m_{H_2O,met} \Delta h_{H_2O}(T) + m_{Oil,met} \Delta h_{Oil}(T) \quad (12)$$

missä  $m_{Dust,met,i}$  on komponentin i massa panosmateriaalista pölyssä [kg/t],  
 $m_{Slag,met,i}$  on komponentin i massa panosmateriaalista kuonassa [kg/t],  
 $m_{H_2O}$  on veden osuus panosmateriaalissa [kg/t] ja  
 $m_{Oil}$  on öljyn ja rasvan osuus panosmateriaalissa [kg/t].

Tyypillisesti tuotettua terästonnia kohden syntyy 10-25 kg pölyä. Pölyjä analysoitaessa on saatu selville, että 80-90 % pölyjen koostumuksesta on peräisin ei-rautametalisista materiaaleista panosmateriaalissa. Kun jätetään huomioimatta vesi, rasvat ja öljyt panosmateriaalissa niiden pitoisuuden vaikean määrittämisen vuoksi, voidaan laskea energiantarve pölyjen lämmitykseen 20 °C:sta 900-1200 °C:een. Kuonanmuodostajien entalpioiden avulla voidaan määrittää energiantarve pölyjen lämmitykselle yhtälön (13) avulla. (Kirschen et al. 2004, Pfeifer et al. 2002, Pfeifer et al. 2005)



$$\Delta h_E = 480 - 600 \text{ kWh/t} \quad e_{el,E} = \frac{\Delta h_E}{\eta_{el} \cdot \eta_{arc}} = 600 - 1000 \text{ kWh/t} \quad (13)$$

### 3.4.2 Jäähdytyskierron lämpösisältö

Valokaariuunin jäähdytysvesikierto sitoo energiaa itseensä. Vesikiertoa lämmittäviä energianlähteitä ovat valokaaret, sulasta säteilevä lämpöenergia ja savukaasujen kautta tapahtuva konvektio. Valokaariuunin jäähdytyskierron lämpösisältö voidaan laskea käyttämällä mitattua dataa, kun tiedetään jäähdytyskierron syötteen ja paluukierron lämpötilat ja virtaama. Kokonaisuudessa valokaariuunin jäähdytysysteemi koostuu uunin seinien eli vaipan jäähdytyskierrosta, holvin jäähdytyskierrosta ja savukaasujen jäähdytyskierrosta. Jäähdytysvesikiertoon sitoutuneen energian määrä ja se pystytään laskemaan kaavan (14) avulla. (Pfeifer et al. 2005, Kirschen 2006)

$$E_{Cool} = \Delta H_{Cool} = \int \rho V [h(T_2) - h(T_1)] dt \quad (14)$$

missä  $E_{Cool}$  on jäähdytysveteen sitoutunut energia,  
 $\Delta H_{Cool}$  on jäähdytysveden entalpiamuutos,  
 $\rho$  on tiheys [ $\text{kg/m}^3$ ],  
 $V$  on tilavuusvirtaus [ $\text{m}^3/\text{h}$ ],  
 $T_2$  on jäähdytyskierron syötteen lämpötila [ $^{\circ}\text{C}$ ] ja  
 $T_1$  on paluukierron jäähdytysveden lämpötila [ $^{\circ}\text{C}$ ].

### 3.4.3 Prosessissa syntyvien savukaasujen lämpösisältö

Savukaasujen mukana prosessista pois virtaava energia riippuu savukaasun koostumuksesta, lämpötilasta ja virtaamasta. Yhtälön (15) voidaan laskea savukaasujen lämpösisältö ja niiden lämmittämiseen kuluva energia, kun tiedetään edellä mainitut tekijät. (Kirschen et al. 2005, Kirschen 2006)

$$E_{Offgas} = \Delta H_{Offgas} = \int n_i [h_i(T) - h_i(T_0)] dt + \int [n_{CO} h_{u,CO} + n_{H_2} h_{u,H_2}] dt \quad (15)$$

missä  $n$  on ainemäärävirta ( $\text{mol/s}$ ),  
 $h$  on savukaasukomponenttien entalpia ( $\text{J/mol}$ ),  
 $T$  on savukaasun lämpötila poistoputkessa ( $^{\circ}\text{C}$ ) ja  
 $T_0$  on savukaasun alkulämpötila ( $^{\circ}\text{C}$ ).

### 3.4.4 Lämpösäteilyn aiheuttamat häviöt

Jos valokaariuuniprosessissa käytetään kahden korin panostusta, uuni joudutaan avaamaan panostuksen ajaksi, jolloin tapahtuu lämpöhäviötä säteilemällä. Säteilemällä tapahtuva energiahäviö riippuu merkittävästi siitä, kuinka kauan toisen romukorin panostus kestää ja kuinka suuri valokaariuuni on. Myös se, missä vaiheessa prosessi on menossa vaikuttaa merkittävästi, koska lämpötilojen noustessa lämpösäteilyn määrä lisääntyy. Yhtälössä (16) on kuvattu lämpösäteilemällä prosessista poistuvan energian määrä. (Carlsson et al. 2019, Kirschen 2006)

$$E_{Rad} = \int [\varepsilon \sigma (T_{input}^4 - T_{env}^4) A_{EAF}] dt \quad (16)$$

missä  $\varepsilon$  on pinnan emissiokykykerroin,  
 $\sigma$  on Stefan-Boltzmannin vakio [ $5,6704 \pm 0,00004 \cdot 10 \text{ W/m}^2 \text{ K}^4$ ],  
 $T_{input}$  on uunin panoksen lämpötila [ $^{\circ}\text{C}$ ],  
 $T_{env}$  on uunin ympäröivän alueen lämpötila [ $^{\circ}\text{C}$ ] ja  
 $A_{EAF}$  on uunin pinta-ala [ $\text{m}^2$ ].

### 3.4.5 Vuorauksen lämpösisältö

Uunin vuoraukseen sitoutuu lämpöenergiaa sulatuksen aikana. Tästä seuraa vuorauksen lämpötilan nousua ja vuorauksen olomuodon muutoksia. Vastaavasti, kun prosessissa on ongelmia ja vuoraus jäähtyy tai vuorauksen ollessa uusi, tarvitaan energiaa lämmittämään se haluttuun lämpötilaan. Eniten lämpöenergiaa sitoutuu vuoraukseen sen ollessa uusi. Kuitenkin vuorauksen lämpötilan muutokset ovat hyvin pieniä, kun prosessi toimii oikein. Isoja lämpötilan muutoksia vuorauksessa syntyy vain, kun uuni jäähtyy sulatusten välillä tai aikana. Yhtälössä (17) on esitetty vuorauksen lämpösisältö. Kirschenin et al. (2007) julkaisussa on esitetty uunin vuoraukseen sitoutuvan energian olevan tyypillisesti 4-10 kW/m<sup>2</sup>. Julkaisussa on mainittu, että sitoutuvan energian määrään vaikuttavat vesikierron lämpötilan muutokset, kuonan kuohuminen ja vuorauksen paksuus. Yhtälössä (17) on huomioitavaa, että esimerkiksi Kirschenin et al. (2007) artikkelissa mainittua kuonan kuohumista ei ole otettu huomioon. (Jokilaakso 1987, Kirschen et al. 2007)

$$q_{rfl} = s \cdot \rho \cdot c_p \cdot \left[ \frac{1}{2} \cdot (T_s + T_u) - T_0 \right] \quad (17)$$

missä  $s$  on seinämän paksuus [m],  
 $\rho$  on tiheys [kg/m<sup>3</sup>],  
 $c_p$  on vuorauksen ominaislämpökapasiteetti [kcal/kg·°C],  
 $T_s$  on vuorauksen sisäpuolen lämpötila [°C],  
 $T_u$  on vuorauksen ulkopuolen lämpötila [°C] ja  
 $T_0$  on vuorauksen alkulämpötila [°C].

### 3.5 Yhteenveto energiantarpeeseen vaikuttavista tekijöistä

Vaikka kaikki mallit, mitä tässä työssä tullaan käymään läpi, eivät perustu aine- ja energiataseisiin, antaa tämä luku kuitenkin kattavan käsityksen siitä mitkä tekijät vaikuttavat merkittävästi valokaariuuniprosessin energiantarpeeseen. Erityisesti se, mistä häviöt prosessin aikana syntyvät, selviää tämän luvun perusteella hyvin. Hyvä esimerkki häviöstä, joka on pystytty havaitsemaan myös prosessidatasta, on luvussa 3.4.5 esitetty uuden vuorauksen lämmitykseen tarvittava lisäenergia. Sama ilmiö on havaittu myös luodessa sulatusajan optimointimallia, joka käydään läpi luvussa 5.

## 4 VALOKAARIUUNIN PROSESSIMALLIT

Tässä luvussa käydään läpi erilaisia prosessimalleja valokaariuuniprosessille. Mallilla pyritään kuvaamaan todellisia tapahtumia valokaariuunissa. Mallit voivat olla hyvin yksinkertaisia tai monimutkaisia, mutta yleensä niitä on yksinkertaistettu käytön helpottamiseksi. Prosessimallien avulla voidaan laskea panos valokaariuunille, määrittää paljonko energiaa panoksen sulatukseen tarvitaan prosessin aikana ja mallintaa ilmiöitä prosessin aikana. Prosessimalleja käytetään prosessin ohjaamiseen ja niiden kehittämiseen. Erityisesti jatkuva raaka-aineiden hinnan kasvu on ajanut teräksen valmistajat kehittämään valokaariuuniprosessia tehokkaammaksi joka osa-alueella. Moni valmistaja on pyrkinyt korvaamaan sähköenergiaa prosessissa kemiallisella energialla. Laskennallisilla malleilla voidaan kuvata prosessissa tapahtuvia yksittäisiä ilmiöitä, kuten savukaasujen virtausta CFD-mallinnuksen avulla. Ilmiöpohjaisessa mallinnuksessa voidaan koota useita ilmiöitä kuvaavia malleja kuvaamaan prosessia. Tällöin ilmiöpohjaisia mallinnustapoja voidaan käyttää käytännössä paremmin. Ilmiöpohjaiset mallit voivat sisältää myös empiirisiä korjausparametreja. Prosessilähtöinen mallinnus tehdään usein juuri tietylle prosessille, jolloin sen käyttö muissa sovelluksissa on hankalaa. Tällaiset mallit kuvaavat usein todella hyvin sitä sovelluskohdetta, jolle se on luotu, koska malli perustuu tietyn prosessin sisään- ja ulostuloihin. Seuraavassa on käyty läpi kirjallisuudessa esitettyjä malleja, ja ne on jaettu offline- ja ohjausmalleihin.


### 4.1 Offline-mallit

Offline-malleja käytetään keräämään lisätietoa valokaariuuniprosessista ja niitä ei käytetä prosessinohjaukseen. Ne ovat käytössä erityisesti kehitystoiminnassa ja niiden avulla pyritään kehittää ymmärrystä valokaariuuniprosessin etenemisestä ja erityisesti parametreista, joita tällä hetkellä ei ole mahdollista mitata.

#### 4.1.1 Energian tarpeen määrittäminen empiirisillä malleilla valokaariuunille

Empiiristen mallien avulla on mahdollista laskea energiantarve valokaariuuniprosessille. Energian ja raaka-aineiden hintojen noustessa valokaariuunien käyttökustannukset kasvavat jatkuvasti. Tästä syystä on kehitetty runsaasti malleja, joiden avulla voidaan selvittää valokaariuuniprosessin sähkönkulutus. Mallit ottavat huomioon, miten muiden energianlähteiden tuottama energia ja energiahukkiin kuluva energia vaikuttavat

sähköenergian tarpeeseen prosessissa. Empiiriset mallit perustuvat esimerkiksi lineaariseen regressioon, joka on määritetty kattavan prosessidatan pohjalta useista eri valokaariuuneista tai yksittäisestä valokaariuunista. Yksittäiselle valokaariuunille tehdyt mallit kuvaavat prosessia yleensä paremmin kuin monen eri valokaariuunin prosessidatan perusteella luodut mallit. Tämä johtuu siitä syystä, että valokaariuuniprosesseissa on suuria eroavaisuuksia monella eri osa-alueella. Kuvassa 11 on esitetty valokaariuunin sähköenergian tarpeeseen vaikuttavia parametreja, joita empiiriset mallit käyttävät sähkönkulutuksen määrittämisessä. (Pfeifer et al. 2005, Kirschen et al. 2017)



Kuva 11. Valokaariuunin sähkönkulutukseen vaikuttavia tekijöitä (mukaiillen Kirschen et al. 2017).

#### 4.1.2 Köhlen malli

Vuonna 1992 Köhle julkaisi valokaariuunin sähköenergian  $W_R$  tarvetta kuvaavan lineaarisen mallin, joka perustuu kokeelliseen dataan. Se ottaa huomioon lukuisia tekijöitä, jotka vaikuttavat valokaariuunin energiataseeseen. Myöhemmin vuosina 1999, 2001 ja 2002 mallia kehitettiin ja laajennettiin kattavammaksi. Taulukossa 6 on esitetty Köhlen mallin kehitys ja termit. Köhlen malli soveltuu niin vaihtovirta- kuin

tasavirtauuneille. Mallissa olevat kertoimet on määritetty lineaarisen regression avulla prosessidatasta. Köhlen mallin virhe verrattuna todelliseen sähköenergian kulutukseen on tarkasteltaessa yhtä sulatusta kohden noin 25 kWh/t ja pidemmän aikavälin tarkastelussa 10 kWh/t. Kirschenin et al. (2017) julkaisussa on määritetty Köhlen mallille  $R^2=0,31$ , joka on alhainen selitysaste. Samassa julkaisussa on verrattu Köhlen mallia uuteen regressiomalliin, jonka  $R^2=0,96$ . Mallin huomattavasti parempi selitysaste johtuu todennäköisimmin siitä, että malli on kehitetty juuri tietyille uunille. Mallin tarkoitus on ollut käyttäjäystävällisyys, minkä seurauksena siitä on jätetty huomiotta vaikeimmin selvitettäviä termejä. Malli olettaa lineaarisen riippuvuuden sähköenergian tarpeen, prosessiparametrien ja syötteiden välillä. Mallia käyttäessä tulee ottaa huomioon, että jokainen valokaariuuniprosessi eroaa toisistaan jossain määrin. (Pfeifer et al. 2005, Kirschen et al. 2017)

Taulukko 6. Köhlen malli (Pfeifer et al. 2005).

$\frac{W_R}{\text{kWh/t}} = 300 + 900 \cdot \left[ \frac{G_E}{G_A} - 1 \right] + 1600 \cdot \frac{G_Z}{G_A} + 0.7 \cdot \left[ \frac{T_A}{^{\circ}\text{C}} - 1600 \right] + 0.85 \cdot \frac{t_s + t_N}{\text{min}} - 8 \cdot \frac{M_G}{\text{m}^3/\text{t}} - 4.3 \cdot \frac{M_L}{\text{m}^3/\text{t}}$		(1)	
		1992 [8]	
$\frac{W_R}{\text{kWh/t}} = 300 + 900 \cdot \left[ \frac{G_E}{G_A} - 1 \right] + 1600 \cdot \frac{G_Z}{G_A} + 0.7 \cdot \left[ \frac{T_A}{^{\circ}\text{C}} - 1600 \right] + 0.85 \cdot \frac{t_s + t_N}{\text{min}} - 8 \cdot \frac{M_G}{\text{m}^3/\text{t}} - 4.3 \cdot \frac{M_L}{\text{m}^3/\text{t}}$ $- 2.8 \cdot \frac{M_N}{\text{m}^3/\text{t}} + 80 \cdot \frac{G_{\text{DRI+HBI}}}{G_A} - 300 \cdot \frac{G_{\text{HM}}}{G_A} - 15 \cdot \text{CON}$		(2)	
		1999 [7]	
$\frac{W_R}{\text{kWh/t}} = 391 + 450 \cdot \left[ \frac{G_E}{G_A} - 1 \right] + 800 \cdot \frac{G_Z}{G_A} + 0.35 \cdot \left[ \frac{T_A}{^{\circ}\text{C}} - 1600 \right] + 0.43 \cdot \frac{t_s + t_N}{\text{min}} - 2.1 \cdot \frac{M_L}{\text{m}^3/\text{t}}$		(3)	
		2001 [10]	
$\frac{W_R}{\text{kWh/t}} = 375 + 400 \cdot \left[ \frac{G_E}{G_A} - 1 \right] + 1000 \cdot \frac{G_Z}{G_A} + 0.3 \cdot \left[ \frac{T_A}{^{\circ}\text{C}} - 1600 \right] + 1.00 \cdot \frac{t_s + t_N}{\text{min}} - 8 \cdot \frac{M_G}{\text{m}^3/\text{t}} - 4.3 \cdot \frac{M_L}{\text{m}^3/\text{t}}$ $- 2.8 \cdot \frac{M_N}{\text{m}^3/\text{t}} + 80 \cdot \frac{G_{\text{DRI+HBI}}}{G_A} - 350 \cdot \frac{G_{\text{HM}}}{G_A} - 50 \cdot \frac{G_{\text{SHR}}}{G_A} + \text{NV} \cdot \frac{W_V - W_{\text{vm}}}{\text{kWh/t}}$		(4)	
		2002 [9]	
CON	continuous (+1), discontinuous (-1) operation	$M_N$	Specific post-combustion oxygen [ $\text{m}^3/\text{t}$ ]
$G_A$	Furnace tap weight [t]	NV	Furnace specific factor (0.2 to 0.4)
$G_{\text{DRI}}$	Weight of DRI (Direct Reduced Iron) [t]	$T_A$	Tapping temperature [ $^{\circ}\text{C}$ ]
$G_E$	Weight of all ferrous materials [t]	$t_N$	Power-off time [min]
$G_{\text{HBI}}$	Weight of HBI (Hot Briquetted Iron) [t]	$t_s$	Power-on time [min]
$G_{\text{HM}}$	Weight of hot metal [t]	$W_R$	Specific electric energy demand (from regression analysis) [kWh/t]
$G_{\text{SHR}}$	Weight of shredder [t]	$W_V$	Energy losses (if measured) [kWh/t]
$G_Z$	Weight of slag formers [t]	$W_{\text{vm}}$	Mean value of $W_V$ [kWh/t]
$M_L$	Specific lance oxygen [ $\text{m}^3/\text{t}$ ]		
$M_G$	Specific burner gas [ $\text{m}^3/\text{t}$ ]		

#### 4.1.3 Adamsin malli

Adamsin malli kuvaa valokaariuuniprosessin kokonaisenergian  $W_{\text{tot}}$  tarvetta. Adamsin ja Köhlen mallit ovat hyvin samankaltaisia, mutta Köhlen mallissa referenssiarvo on kaatopaino  $G_A$  ja Adamsin mallissa panospaino  $G_E$ . Adamsin malli on määritetty 92 valokaariuunin prosessidatan pohjalta. Taulukossa 7 on esitetty vuonna 2001 ja 2002 julkaistut Adamsin mallit ja niiden termit. Adamsin ja Köhlen malleissa on myös eroavaisuuksia parametreissa, jotka ne ottavat huomioon. Adamsin malli ei ota huomioon kaatolämpötilaa, kaadosta kaatoon-aikaa, kuonanmuodostajien määrää ja silputun romun määrää. Köhlen malli ei vastaavasti ota huomioon polttimien syötteen öljyn ja nestekaasun määrää.

Taulukko 7. Adamsin malli (Pfeifer et al. 2005).

$\frac{W_{\text{tot}}}{\text{kWh/t}} = \frac{W_E}{\text{kWh/t}} + 110 \cdot \frac{G_{\text{PI}}}{G_E} - 100 \cdot \frac{G_{\text{DRHBI}}}{G_E} + 450 \cdot \frac{G_{\text{HM}}}{G_E} + 10.5 \cdot \frac{M_G}{\text{m}^3/\text{t}} + 5.2 \cdot \frac{M_{\text{O}_2} - 2.0 \cdot M_G}{\text{m}^3/\text{t}}$		(5) 2001 [13]	
$\frac{W_{\text{tot}}}{\text{kWh/t}} = \frac{W_E}{\text{kWh/t}} + 110 \cdot \frac{G_{\text{PI}}}{G_E} - 100 \cdot \frac{G_{\text{DRHBI}}}{G_E} + 450 \cdot \frac{G_{\text{HM}}}{G_E} + 10.5 \cdot \frac{M_G}{\text{m}^3/\text{t}} + 11 \cdot \frac{M_{\text{OI}}}{\text{l/t}} + 8 \cdot \frac{M_{\text{LPG}}}{\text{l/t}} + 5.2 \cdot \frac{M_{\text{O}_2} - 2.0 \cdot M_G - 2.0 \cdot M_{\text{OI}} - 1.5 \cdot M_{\text{LPG}}}{\text{m}^3/\text{t}}$		(6) 2002 [14]	
$G_E$	Weight of input [t]	$M_{\text{OI}}$	Specific volume of oil input [l/t]
$G_{\text{PI}}$	Weight of pig iron [t]	$M_{\text{LP}}$	Specific volume of LPG (liquefied petrol gas) [l/t]
$M_{\text{O}_2}$	Specific volume of oxygen [m <sup>3</sup> /t]	$W_E$	Specific electric energy input [kWh/t]

#### 4.1.4 Carlssonin ja muiden tilastolliset mallit

Carlssonin et al. (2019) julkaisussa on esitetty tilastollisia malleja valokaariuunille. Erityisen mielenkiintoisia ovat taulukossa 8 esitetyt yhtälöt, jotka kuvaavat, miten eri tekijät vaikuttavat valokaariuunin sähköenergian tarpeeseen. Yhtälöt kuvaavat valokaariuunin energiatasetta, jossa on eritelty sisään- ja ulostulot. Sisääntuloina ovat sähköenergia, kemiallinen energia ja polttimilta saatava energia. Ulostuloina on teräkseen, kuonaan, savukaasuihin, pölyyn ja vesikiertoon sitoutunut energia, ja lisäksi säteilyn, konvektion ja muuntajan energiahäviöt. Nämä yhtälöt ovat hyvin samanlaisia kuin aiemmissa malleissa esitetyt tekijät. Julkaisussa on kuitenkin esitetty, millaisia riippuvuuksia yhtälöillä on. Esimerkiksi sähköenergian käyttöön teräksen sulattamiseksi vaikuttavat teräksen syöttö- ja ulostulolämpötilat ja teräksen koostumus. Taulukon 8 termit on avattu liitteessä 1. (Carlsson et al. 2019)

Taulukko 8. Energiataseeseen vaikuttavat tekijät. (Carlsson et al. 2019)

	Energy Factor	Description	Equation	Proportionality
In	$E_{EI}$	Total Electrical Energy (EE) output from transformer	$E_{EI} = \eta_{Arc} \cdot \eta_{EI} \cdot P_{Avg} \cdot t_{PON}$	$E_{EI} \propto t_{PON}$
	$E_{Chem}$	Total energy from chemical reactions in steel and slag	$E_{Chem} = \sum \Delta H_{298}^0(products) - \sum \Delta H_{298}^0(reactants) + \int_{T_s}^{T_{Tap}} \left[ \sum c_p(products) - \sum c_p(reactants) \right] dT$	$E_{Chem} \propto T_s; T_{Tap}; composition$
	$E_{Bu}$	Total energy input from burner	$E_{Bu} = \eta_{Fuel} h_{Fuel} V_{Fuel}$	$E_{Bu} \propto V_{Fuel}; \eta_{Fuel}$
Out	$E_{Steel}$	Total energy output to steel	$E_{Steel} = H_{Melt,steel} + m_{Steel} \cdot c_{Steel} \int_{T_s}^{T_{Tap}} dT$	$E_{Steel} \propto T_s; T_{Tap}; composition$
	$E_{Slag}$	Total energy lost in slag	$E_{Slag} = H_{Melt,slag} + m_{Slag} \cdot c_{Slag} \int_{T_s}^{T_{Tap}} dT$	$E_{Slag} \propto T_s; T_{Tap}; composition$
	$E_{Gas}$	Total energy lost in gas	$E_{Gas} = \frac{PM\dot{V}_{Gas}}{R} \cdot t_{TTT} \cdot c_{Gas} \int_{T_s}^{T_{Offgas}} \frac{dT}{T}$	$E_{Gas} \propto \ln(T_s); \ln(T_{Tap}); t_{TTT}; \dot{V}_{Gas}$
	$E_{Dust}$	Total energy lost in dust	$E_{Dust} = \dot{m}_{Dust} \cdot t_{TTT} \cdot c_{Dust} \int_{T_s}^{T_{Offgas}} dT$	$E_{Dust} \propto T_s; T_{Tap}; t_{TTT}; \dot{m}_{Dust}$
	$E_{Cooling}$	Total energy lost in cooling water	$E_{Cooling} = k A_{CS} (T_{CS} - T_{H2O}) \cdot t_{TTT}$	$E_{Cooling} \propto T_{CS}; t_{TTT}$
	$E_{Rad}$	Total energy lost through radiation	$E_{Rad} = \epsilon \sigma A_{EAF} T_{EAF}^4 \cdot t_{TTT}$	$E_{Rad} \propto T_{EAF}^4; t_{TTT}$
	$E_{Conv}$	Total energy lost through convection	$E_{Conv} = h A_H (T_H - T_{Amb}) \cdot t_{TTT}$	$E_{Conv} \propto T_H; T_{Amb}; t_{TTT}$
	$E_{EI,loss}$	Energy lost in electrical system and arc transfer	$E_{EI,loss} = (1 - \eta_{Arc})(1 - \eta_{EI}) \cdot E_{EI}$	$E_{EI,loss} \propto t_{PON}$


#### 4.1.5 Neuroverkkoihin perustuvat mallit

Neuroverkkojen kehitys lähti liikkeelle lineaaristen mallien kehityksestä ja laajentamisesta. Neuroverkkojen avulla pyritään luomaan matemaattisia yhteyksiä prosessin syötteiden ja ulostulojen välille. Niiden avulla pystytään luomaan prosessimalleihin tarkempia kertoimia kuvaamaan valokaariuunin toimintaa. Kun neuroverkkoon syötetään prosessin syöte sen kulkiessa neuroverkon läpi, saadaan



tulokseksi prosessin ulostulo. Neuroverkon neuronit ovat systeemin tiedonkäsittely-yksiköitä, niiden välille voidaan asettaa kertoimia riippuen niiden vaikutuksesta toisiinsa. Esimerkkinä tällaisesta toimii Baumertin et al. (2002) luoma neuroverkko, joka kuvaa uunin käyttämää sähköenergiaa 10 mittapisteen perusteella. Malli perustuu Köhlen mallin laajentamiseen neuroverkkojen avulla. Kun tähän neuroverkkoon lisättiin vaimennuskerroin, saatiin malli, joka pystyi ennustamaan todellisen sähkönkulutuksen tarpeen tarkkuudella  $\pm 2,5$  MWh/sulatus. Kehitetty vaimennuskerroin ei ottanut huomioon millään tapaa metallurgiaa tai prosessia. Tämä virhe on huomattavasti pienempi kuin Köhlen mallin virhe. Vaikka empiiriset mallit suoriutuvat paremmin kuin teoreettiset, niistä puuttuu kyky tarkastella, mitkä sisääntuloarvot vaikuttavat prosessin energiantarpeeseen. (Baumert et al. (2002), Carlsson et al. 2019, Gajic et al. 2016, Pfeifer et al. 2005)

Gajicin et al. (2016) luomassa mallissa pyrittiin mallintamaan sähköenergian kulutusta syötetyn kierrätysromun hiili-, kromi-, nikkeli-, pii- ja rautapitoisuuksien avulla. Tästä määrittämisestä nousee ensimmäisenä mieleen vaikeus analysoida isoja romueriä tarkasti. Muita tärkeitä ominaisuuksia, joita mallin luonnissa seurattiin, olivat romun tyyppi ja koostumus, käytettävä kemiallinen energia sekä sulan lämpötilan pitäminen tasaisena. Opettamalla neuroverkkoa ja vertaamalla tuloksia laboratoriossa määriteltäisiin pitoisuuksiin saatiin mallinnus sähköenergian kulutuksesta. Neuroverkko vertaili edellä mainittujen alkuaineiden pitoisuuksia ottamalla huomioon niiden erilaiset sulamislämpötilat. Tämän avulla saatiin selville, millä alkuaineilla oli suurin vaikutus sähköenergian kulutukseen. Tuloksena saatiin selville, että suurin vaikutus sähköenergian tarpeeseen on panoksen hiilipitoisuudella. Tätä mallia hyödyntäen pystytään ottamaan huomioon pitoisuuksien vaihtelut panoksessa ja optimoimaan prosessia sen pohjalta ja tärkeimpänä vähentämään sähköenergian käyttöä. Kuvassa 12 on esitetty määritetyt ja mallinnetut sähköenergian tarpeet 46 sulatukselle. Malli pystyy osan ajasta mallintamaan sähköenergian tarpeen hyvin tarkasti, mutta osan ajasta erot mallinnuksessa ja mitatuissa arvoissa ovat hyvin suuria, validointivaiheessa jopa 30 kWh/t. Vaikka mallin selitysaste  $R^2 = 0,92$  antaa ymmärryksen siitä, että malli kuvaa yleisesti prosessia hyvin, tuovat suuret yksittäiset poikkeamat epävarmuuden sen käytöstä todellisuudessa. Tämän vuoksi suuren selitysasteen mallit eivät todellisuudessa pysty vastaamaan yksistään prosessinohjauksesta. Yhtenä tekijänä tähän voi olla aikaisemmin mainittu vaikeus määrittää panoksen kemiallinen koostumus. (Gajic et al. 2016)




Kuva 12. Mallin ennustama sähköenergian kulutus verrattuna mitattuun sähköenergian kulutukseen (mukaillen Gajic et al. 2016).

Syväoppimisen tavoitteena on luoda parametrien avulla neuroverkko, joka pystyy ratkaisemaan sille annetut ongelmat. Syväoppimisella tarkoitetaan laajaa neuroverkkoa, mutta mitään tarkkaa rajaa ei kuitenkaan ole määritelty sille, milloin neuroverkoista aletaan käyttää nimitystä syväoppiminen. Malli opetetaan syöttämällä sille muuttujia, kuten romun tyyppi, kaadosta kaatoon -aika ja kuonan muodostajien määrä. Malli mahdollistaa vuorovaikutusten huomaamista eri tekijöiden välillä, joita ennen on ollut hyvin vaikea selvittää. Mitä laadukkaampaa ja laajempaa datajoukkoa syväoppimisessa voidaan käyttää, sitä tehokkaammaksi se kehittyy. (Carlsson et al. 2019, Chen et al. 2018)

#### 4.1.6 ThyssenKrupp Nirosta Bochum & Krefeld

Kirschen et al. (2002) julkaisussa määritettiin aine- ja energiataseet kahdelle valokaariuunille savukaasumittauksien avulla. Valokaariuunit olivat ThyssenKrupp Nirostan Bochumissa sijaitseva 145 tonnin uuni ja Krefeldissä sijaitseva 75 tonnin uuni. Uunien kokoluokan lisäksi uuneissa oli erona se, että Krefeldissä käytettiin kaasupolttimia ja Bochumissa ei. Savukaasuista mitattiin niiden lämpötilaa, koostumusta

ja tilavuusvirtausta. Näillä mittauksilla saatiin riittävästi tietoa prosessista, jotta aine- ja energiatase pystyttiin selvittämään muiden prosessimittausten avulla. Aine- ja energiataseet on esitetty seitsemän austeniittisen sulatuksen keskiarvona 145 tonnin uunille ja 24 austeniittisen sulatuksen keskiarvona 75 tonnin uunille. Kuvassa 13 on esitetty molempien uunien energiataseet. (Kirschen et al. 2002)



Kuva 13. 145 tonnin ja 75 tonnin valokaariuunien energiataseet (mukailleen Kirschen et al. 2002).

Taulukossa 9 esitettyjä tuloksia tutkittaessa huomataan, että molemmat uunit käyttävät lähes saman verran kokonaisenergiaa: 145 tonnin uuni käyttää 758 kWh/t ja 75 tonnin uuni käyttää 742 kWh/t. Uunien välillä on kuitenkin eroa, mistä energia on peräisin, mikä johtuu 145 tonnin uunin vuotoilman suuremmasta määrästä, josta seuraa myös suurempi savukaasujen entalpia. Savukaasujen koostumus vaihteli merkittävästi uunien välillä, koska toisessa käytettiin happi-kaasupolttimia ja toisessa ei. Suurempi vuotoilman määrä 145 tonnin unissa johtuu happi-kaasupolttimien puutteesta. Julkaisussa energia- ja ainetaseiden tarkkuutta ei ole määriteltä muuten kuin ilmoittamalla niiden olevan tarkkoja. (Kirschen et al. 2002)

Taulukko 9. Krefeldin ja Bochumin uunien tekniset tiedot (Kirschen et al. 2002).

	Bochum	Krefeld
Start up date	1982	1985
Transformer apparent power [MVA]	135	70
Primary voltage [kV]	33	25
Secondary voltage [V]	700 - 1200	455 - 802
Current [kA]	62-84	50-52
Mean tapping weight [t]	145	75
Annual productivity [t/y]	720000	530000
Shell diameter [m]	6.9	5.9
Electrode diameter [mm]	650	550
Wall cooling system	Steam cooling	Steam cooling
Roof cooling system	Water cooling	Steam cooling
Number of wall cooling panels	14	11
Gas burner	no	yes
Primary off-gas extraction [Nm <sup>3</sup> /h]	165.000	60.000
Secondary off-gas extraction [Nm <sup>3</sup> /h]	660.000	400.000
Tapping system	Skimmer	Runner
Tapping temperature [°C]	1550	1550-1600
Additional equipment:	Current conducting electrode arms Digital electrode control system Oxygen lance manipulator Process control computer	

#### 4.1.7 Valokaariuuniprosessin mallinnus taloudellisesta näkökulmasta

Terästä valmistavat yritykset ovat useimmiten pörssiyhtiöitä, jotka haluavat maksimoida tuoton. Tällöin on tärkeää seurata myös prosessien taloudellista puolta, jonka avulla voidaan maksimoida voittoja. Esimerkiksi riippuen raaka-aineiden hinnoista voidaan prosessia optimoida taloudellisesti kannattavammaksi. Valokaariuuniprosessia tarkasteltaessa taloudelliselta näkökannalta tulee määrittää tekijät, jotka vaikuttavat prosessin kuluihin. Kulut voidaan jakaa raaka-ainekuluihin ja kuluihin, joita syntyy, kun ei päästä tavoitteisiin prosessissa. (Oosthuizen et al. 2004)

Raaka-aineina uuniin panostettavat materiaalit eritellään ja asetetaan jokaiselle niille yksikköhinta, jonka perusteella lasketaan panosmateriaalien kustannukset uunissa. Camdalín et al. (2012) julkaisussa on esitetty uunin materiaalisyyötteiden ja ulostulojen hinnat. Taulukossa 10 ei ole esitetty käytetyn sähköenergian hintaa ja määrää, joka on merkittävä osa valokaariuuniprosessin kustannuksista. Sähköenergian tarve prosessissa voidaan määrittää energiataseen avulla ja näin laskea kulut, jotka syntyvät sähköön käytöstä prosessissa. Tähän sähköön käyttöön voidaan ottaa myös huomioon tukiprosessien käyttämä sähköenergia. Myös kuonan hinnaksi ulostulona on merkitty

nolla. Esimerkiksi Biancon et al. (2018) julkaisussa, jossa on avattu kiertotaloutta terästehtaissa, käydään läpi kuonan käyttöä maarakennuksessa. Tällaisissa tapauksissa kuonalle tulisi asettaa hinta prosessin ulostuloihin. Myös paljon arvokkaita komponentteja sisältäviä kuonia voidaan jalostaa kuonasulatoissa, jolloin voidaan saada kuonista myös positiivista tuottoa prosessin ulostuloina. Tällaista kuonasulattoa on suunniteltu myös Tornion terästehtaalte. Valokaariuuniprosessissa syntyvät pölyt sisältävät myös paljon arvometalleja ja niille taulukossa 10 on asetettu hinta lopputuotteisiin. (Camdali et al. 2012, Bianco et al. 2018 & Yle 2019)

Taulukko 10. Valokaariuunisyötteiden ja ulostulojen määrät sekä hinnat (Camdali et al. 2012).

Inlet to EAF	Mass amount, ton	Mass amount (ton; for 1 ton liquid steel)	Mass amount (kg; for 1 ton liquid steel)	Unit price, \$/ton	Price (for 1 ton liquid steel; \$/ton)	Total price, \$
Scrap (production waste)	17.500	0.318	318.182	111.000	35.318	1,942.500
Scrap (heavy melting scraps)	10.000	0.182	181.818	111.000	20.182	1,110.000
Scrap (shredder)	12.500	0.227	227.273	111.000	25.227	1,387.500
Scrap (DKP)	10.000	0.182	181.818	111.000	20.182	1,110.000
Pig iron	7.500	0.136	136.364	120.000	16.364	900.000
Coke	1.000	0.018	18.182	99.000	1.800	99.000
Lime	1.500	0.027	27.273	240.000	6.545	360.000
Limestone	1.000	0.018	18.182	30.400	0.553	30.400
Aldexo	0.200	0.004	3.636	896.000	3.258	179.200
Silica ferro manganese	0.350	0.006	6.364	470.000	2.991	164.500
Aluminum	0.050	0.001	0.909	1,400.000	1.273	70.000
Electrode	0.150	0.003	2.727	1,890.000	5.155	283.500
Natural gas	0.131	0.002	2.386	240.000	0.573	31.495
Oxygen (net)	3.510	0.064	63.821	76.000	4.850	266.770
Cooling water	600.000	10.909	10,909.091	0.300	3.273	180.000
Total	665.391	12.098	12,098.025	5,905.700	147.543	8,114.864

Outlet from EAF	Mass amount, ton	Mass amount (ton; for 1 ton liquid steel)	Mass amount (kg; for 1 ton liquid steel)	Unit price, \$/ton	Price (for 1 ton liquid steel; \$/ton)	Total price, \$
Liquid steel	55.000	1.000	1,000.000	157.000	157.000	8,635.000
Steel in slag	0.300	0.005	5.455	0.000	0.000	0.000
Dusts	3.116	0.057	56.654	2.170	0.123	6.762
Slag	2.741	0.050	49.842	0.000	0.000	0.000
Stack gases	4.234	0.077	76.983	0.000	0.000	0.000
Cooling water	600.000	10.909	10,909.091	0.600	6.545	360.000
Total	665.391	12.098	12,098.025	159.770	163.668	9,001.762

Kun prosessissa ei pysytä haluttujen prosessiparametrien sisällä, syntyy ylimääräisiä kuluja prosessissa. Optimaaliseksi paineeksi valokaariuunin sisällä on määritetty 5 Pascalia alle normaalin ilmanpaineen. Ylipaine aiheuttaa turvallisuusuhan, koska uunissa syntyvät kaasut virtaavat tehdashalliin. Liiallinen alipaine aiheuttaa ylimääräistä energian kulutusta, kun savukaasut virtaavat ulos uunista liian tehokkaasti. Jos savukaasujen


lämpötila on liian korkea, on mahdollista, että suodnlaitoksen suotimet vaurioituvat. Tästä syystä prosessi joudutaan keskeyttämään, minkä seurauksena kaadosta kaatoon -aika pitenee ja syntyy kuluja. Euroopassa olevan päästökaupan seurauksena jokaista tuotettua hiilidioksiditonnia kohden tulee maksaa määrätty summa rahaa. Tämän takia on erityisen tärkeää seurata ja pyrkiä vähentämään valokaariuunin hiilidioksidipäästöjä. Jos terässulan hiilipitoisuus ei ole halutulla alueella, riippuen terästehtaasta voidaan sitä joutua laskemaan valokaariuunissa tai AOD:lla. Tästä seuraa pidempiä prosessointiaikoja sulalle ja tuotannon menettämistä. Sulan lämpötilan halutaan tyypillisesti olevan 10 asteen sisällä määritetystä optimaalisesta lämpötilasta. Erityisesti, jos sulan lämpötila on merkittävästi liian korkea, on todennäköistä, että on käytetty liian paljon sähköenergiaa, mistä aiheutuu lisää kuluja. Jos sulan paino on merkittävästi matalampi kuin panoslaskenta on määrittänyt, se voidaan laskea häviöksi. Esimerkiksi on mahdollista, että kaikkea panostettua romua ei ole sulatettu tai että romun koostumus ei ole ollut sama kuin mitä panoslaskennassa on oletettu. Jos prosessin kuona ei toimi halutusti, eli se ei kuohu niin kuin on oletettu, valokaarten hyötysuhde laskee. Edellä mainitut tekijät voidaan määrittää prosessimallien tai mittausten avulla ja luoda malli siitä, kuinka tehokkaasti valokaariuuni toimii näiden tekijöiden perusteella. (Oosthuizen et al. 2001 & Oosthuizen et al. 2004)

Tehtaasta riippuen kustannukset ja prosessit vaihtelevat toisistaan merkittävästi. Kun tutkitaan valokaariuunin käyttökustannuksia, tulee huomioida millainen teräksen valmistusketju on kokonaisuudessaan: mitkä ovat tuotannon pullonkauloja, millainen valokaariuuniprosessi on ja käytetäänkö esimerkiksi sulaa metallia jostain toiselta prosessipaikalta vähentämään valokaariuunin sulatustarvetta? Myös kiinteät kustannukset, kuten työvoima, tulee ottaa huomioon, kun lasketaan kokonaiskustannuksia. Kuten prosessimallia luodessa myös taloudellista mallia luodessa tulee selvästi rajata, mitä tekijöitä malli kuvaa ja mitkä se jättää huomioimatta. Valokaariuunin taloudellisen mallin avulla voidaan myös tutkia, miten hinnan vaihtelut raaka-ainemateriaaleissa vaikuttavat prosessin kannattavuuteen ja onko joidenkin materiaalien korvaaminen toisilla kannattavaa vallitsevan markkinatilanteen kannalta. Tällaisesta voi olla esimerkkinä kierrätettävän romun korvaaminen ferrokromisulalla tai vastaavasti ferrokromisulan korvaaminen kierrätysromulla. Erityisesti ruostumattomia teräksiä valmistettaessa tulee huomioida, ettei arvometalleja päädy ylimäärin kuonaan pelkistymisen epäonnistuessa, mistä seuraa merkittäviä tappioita valokaariuunin

panosmateriaalien käytössä ja kromipitoisuuden kasvattamisessa seuraavissa prosessivaiheissa.

#### 4.1.8 Matemaattinen mallinnus valokaariuunille

Logarin & Dovzanin (2012) tekemän julkaisun ensimmäisessä osassa on esitetty matemaattinen malli kuvaamaan lämmön- ja aineensiirtoa valokaariuunissa. Valokaariuuni on 3-vaiheinen 80 MVA-vaihtovirtauuni. Osassa yksi kuvataan matemaattisesti aineensiirtomalli, lämpötilan muutosmalli ja lämmönsiirtomalli. Kun tarkastellaan lämmönsiirtoilmiöitä valokaariuunissa, on oletettu, että lämmönsiirtoa tapahtuu johtumalla, konvektiolla ja säteilemällä. Kuvassa 14 on kuvattu valokaariuunin vyöhykkeet uunin sisällä: kaasufaasi, kiinteä romu, sula kuona, sula teräs ja kiinteä kuona. Samassa kuvassa on merkitty uunin rakenteista vyöhykkeiksi uunin katto ja seinät. Johtumalla tapahtuu lämmönsiirtoa vyöhykkeiden välillä, jotka ovat kontaktissa toisiinsa. Konvektiota tapahtuu kaasufaasin ja sitä ympäröivien vyöhykkeiden välillä. Säteilyä tapahtuu pintojen välillä, jotka ovat samassa näkökentässä. Valokaariuunin lämpömalli perustuu näihin edellä mainittuihin lämmönsiirtoilmiöihin ja energiataseen yhtälöihin. (Logar & Dovzan 2012)



Kuva 14. Valokaariuunin vyöhykkeet (mukaillen Logar & Dovzan 2012).

Lämpötilan muutos prosessin aikana voidaan määrittää lämpötaseen avulla. Jokaiselle uunin vyöhykkeelle määritellään lämpötilagradientit erikseen. Yhtälössä (18) on esitetty lämpötilagradientti kiinteälle romulle ja kuonalle. Yhtälössä (19) on esitetty lämpötilagradientti sulalle kuonalle, sulalle teräkselle ja kaasufaasille. Koska mallia luodessa on tehty oletus, että vyöhykkeet ovat homogeenisiä, jokaisella osa-alueella voidaan vyöhykkeen lämpötila määrittää yhtälöllä (20), jos systeemiin lisätään lisää panosmateriaalia esimerkiksi panostamalla toinen kori. (Logar & Dovzan 2012)

$$\frac{dT_i}{dt} = \frac{Q_i(1 - \frac{T_i}{T_{melt}})}{m_i C_{p,i}} \quad (18)$$

$$\frac{dT_i}{dt} = \frac{Q_i}{m_i C_{p,i}} \quad (19)$$

$$T_i = \frac{T_i m_i + T_{add} m_{add}}{T_{add} m_{add}} \quad (20)$$

missä  $i$  on vyöhyke

$Q_i$  on vyöhykkeelle välitetty energia,

$T_i$  on vyöhykkeen lämpötila,

$T_{add}$  on lisättävän materiaalin lämpötila,

$T_{melt}$  on sulan lämpötila,

$m_{add}$  on lisättävän materiaalin massa,

$m_i$  on vyöhykkeen massa,

$C_{p,i}$  on vyöhykkeen lämpötilakapasiteetti ja

$(1 - \frac{T_i}{T_{melt}})$  on termillä kuvataan energiaa, joka lämmittää vyöhykettä ja

varmistetaan, ettei lämpötila voi nousta yli sulamispisteen.

Mallissa on oletettu vyöhykkeiksi myös uunin katto ja seinät. Tämän vuoksi mallissa on esitetty myös yhtälöt niistä johtuville lämpöhäviöille. Yhtälössä (21) ja (22) on esitetty lämpöhäviöiden yhtälöt. (Logar & Dovzan 2012)

$$\frac{dT_{roof}}{dt} = \frac{-Q_{1-RAD} + \frac{A_1}{A_1 + A_2} Q_{gas-water} - \phi_{1-H_2O} C_{p,H_2O} (T_{roof} - T_{H_2O-in})}{A_1 d_1 \rho_1 C_{p,roof}} \quad (22)$$

$$\frac{dT_{wall}}{dt} = \frac{-Q_{2-RAD} + \frac{A_2}{A_1 + A_2} Q_{gas-water} - \phi_{2-H_2O} C_{p,H_2O} (T_{wall} - T_{H_2O-in})}{A_1 d_1 \rho_1 C_{p,wall}} \quad (23)$$



missä  $\phi_{1\&2-H_2O}$  on veden virtausnopeus [kg/s],  
 $C_{p,H_2O}$  on veden lämpökapasiteetti,  
 $T_{H_2O-in}$  on jäähditysvesikiertoon menevän veden lämpötila,  
 $A_1$  on katon pinta-ala,  
 $A_2$  on seinien pinta-ala,  
 $d_1$  on katon paksuus,  
 $d_2$  on seinän paksuus,  
 $\rho_1$  on katon materiaalin tiheys,  
 $\rho_2$  on seinien materiaalin tiheys,  
 $C_{p,roof}$  on katon lämpökapasiteetti,  
 $C_{p,wall}$  on seinien lämpökapasiteetti ja  
 $\frac{A_1}{A_1+A_2}$  ja  $\frac{A_2}{A_1+A_2}$  on seinien ja katon lämmönsiirtoa kuvaava termi.

Aineensiirtomalli määritetään lämpötase- ja lämpötilagradienttiyhtälöiden avulla. Yhtälöt (24) ja (25) kuvaavat määrää, joka on sulanut kiinteästä sulaksi tietyssä lämpötilassa. Samoilla yhtälöillä voidaan kuvata kiinteän kuonan sulamista sulaksi kuonaksi vaihtamalla termejä. (Logar & Dovzan 2012)

$$m_{sSc} = \frac{Q_{sSc} \frac{T_{sSc}}{T_{melt}}}{\lambda_{sSc} + C_{p,sSc}(T_{melt} - T_{sSc})} \quad (24)$$

$$m_{lSc} = -m_{sSc} \quad (25)$$

missä  $m_{sSc}$  on kiinteän romuvyöhykkeen massa,  
 $m_{sSc}$  on kiinteän romuvyöhykkeen massa,  
 $m_{lSc}$  on sulan vyöhykkeen massa,  
 $\lambda_{sSc}$  on kiinteään romuvyöhykkeeseen sitoutunut lämpöenergia,  
 $C_{p,sSc}$  on kiinteän romuvyöhykkeen massa ja  
 $\frac{T_{sSc}}{T_{melt}}$  on kuvaa energian osuutta, joka sulattaa kiinteää romuvyöhykettä.

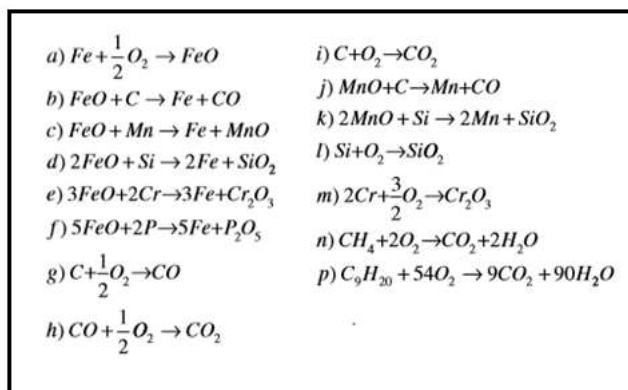
Julkaisun ensimmäisen osan mallit on todettu kokeellisesti hyvin tarkoiksi valokaariuuniprosessin ennustamisessa. Mallille tarvittavat parametrit on määritetty teoreettisen datan ja prosessin aikana tapahtuvien mittausten avulla. Mallia on mahdollista käyttää missä tahansa valokaariuunissa, mutta sitä varten parametrit on määritettävä jokaiselle uunille erikseen. Taulukossa 11 on vertailtu mitattua ja mallilla

simuloitua dataa valokaariuuniprosessille. On kuitenkin otettava huomioon, että mallissa on tehty joitain oletuksia ja yksinkertaistuksia. Esimerkiksi prosessin aikaisten mittausten puutteiden vuoksi on oletettu, että prosessi etenee ideaalisten lämmön- ja aineensiirron lakien mukaan ilman satunnaisia muutoksia. Ja kuten edellä mainittiin, jokaisen uunin vyöhykkeen on oletettu olevan täysin homogeeninen. (Logar & Dovzan 2012)

Taulukko 11. Mitatun ja simuloidun datan vertailu: osa 1 (Logar & Dovzan 2012).

	<i>Fe initial</i> [ton]	<i>Fe end</i> [ton]	<i>Power on time</i> [min]	<i>End steel</i> <i>temperature</i> [K]
Measured	85.3±1.4	81.1±0.9	45.2±3.4	1 961.0±11.6
Simulated	85.0±2.0	82.0±1.4	45.0±2.3	1 958.0±10.5

Logarin & Dovzanin (2012) tutkimuksen toisessa osassa on laadittu malli valokaariuunissa tapahtuville kemiallisille reaktioille ja niissä kuluvalle ja vapautuvalle energialle. Kuten aiemmin tässä työssä ja alan kirjallisuudessa on mainittu, 10-40 % uunin kokonaisenergiasta on peräisin kemiallisista reaktioista. Termodynaamisen mallin luominen valokaariuuniprosessille on tärkeää kahdesta eri syystä, joista ensimmäinen on selvittää reaktioista vapautuneen energian määrä ja toinen on vuorovaikutus eri komponenttien välillä, jolloin voidaan selvittää teräksen, kuonan ja savukaasujen koostumukset. Loganin ja Dovzanin malli olettaa, että kaikki reaktiot tapahtuvat joko sulassa teräksessä tai kuonassa, kuitenkin pois lukien jälkipolton ja happi-kaasupolttimien reaktiot. Kuvassa 15 on esitetty tämän mallin tarkastelemat kemialliset reaktiot. Reaktiot on valittu sen perusteella, kuinka suuri vaikutus niillä on uunin energiataseeseen. Mallissa on esitetty yhtälöt kaikille kuvan 15 reaktioissa esiintyville alkuaineille ja yhdisteille, joiden avulla on mahdollista laskea niiden osuus uunin vyöhykkeissä, joissa niitä esiintyy. (Logar & Dovzan 2012)



Kuva 15. Hapettumis- ja pelkitysmisreaktiot, jotka malli ottaa huomioon (mukaillen Logar & Dovzan 2012).

Mallissa on kuvattu valokaariuunin sisällä olevan kaasufaasin painetta savukaasujen virtauksien, uunissa tapahtuvien reaktioiden, lämpötilan muutoksen sekä hapen ja hiilen lisäyksen avulla. Prosessin aikana elektrodit hapettuvat, mistä vapautuu myös energiaa prosessiin. Tätä energian määrää määritellään virran, elektrodien pinta-alan ja elektrodien kulumiskertoimien avulla. Mallissa on myös runsaasti muita termejä, jotka kuvaavat prosessia, mutta niiden vaikutus prosessissa on huomattavasti pienempi kuin edellä mainittujen tekijöiden. (Logar & Dovzan 2012)

Myös toisessa osassa mallin hyvyttä testattiin 40 todellisen sulatuksen perusteella. Taulukossa 12 on vertailtu simuloitujen ja mitattujen arvojen tuloksia. Malli pystyi ennustamaan hyvin teräksen seosaineiden ja kuonan pitoisuutta. Myös julkaisun toisen osan malliin on tehty tiettyjä yksinkertaistuksia ja olettamuksia. Esimerkiksi aktiivisuuskertoimien on oletettu pysyvän vakiona ja kuonan on oletettu käyttäytyvän ideaalisesti. Kuten osassa yksi myös osassa kaksi on jaettu uuni homogeenisiin vyöhykkeisiin. (Logar & Dovzan 2012)

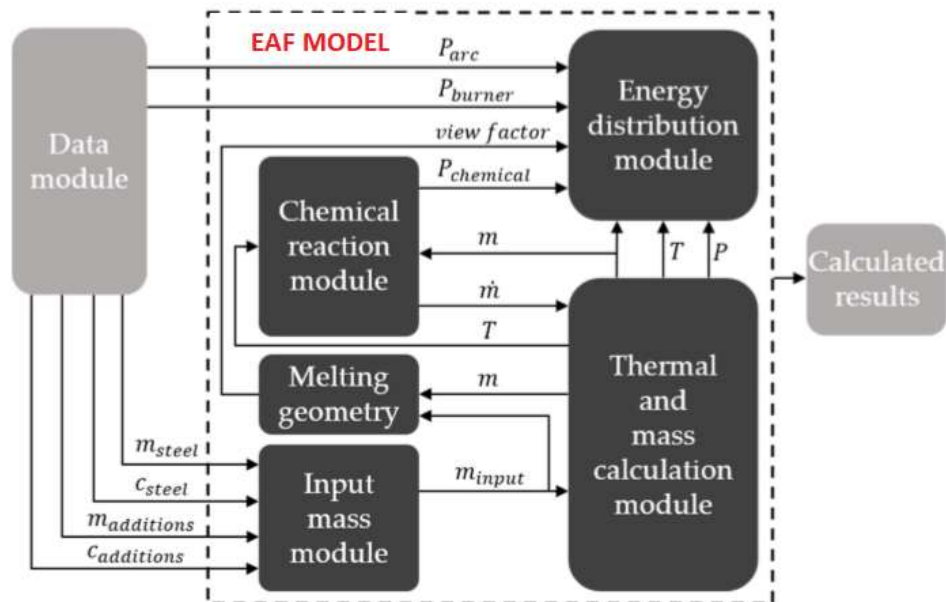
Taulukko 12. Mitatun ja simuloidun datan vertailu: osa 2 (Logar & Dovzan 2012).

	C [%]	Si [%]	Mn [%]	Cr [%]	P [%]			
Measured initial	0.35±0.031	0.57±0.052	0.79±0.079	0.19±0.082	0.05±0.009			
Simulated initial	0.34±0.049	0.59±0.050	0.80±0.053	0.17±0.083	0.05±0.008			
Measured endpoint	0.06±0.009	0.0078±0.0043	0.46±0.042	0.15±0.069	0.007±0.002			
Simulated endpoint	0.061±0.013	0.0061±0.0041	0.45±0.047	0.16±0.049	0.006±0.003			
	FeO [%]	SiO <sub>2</sub> [%]	MnO [%]	Cr <sub>2</sub> O <sub>3</sub> [%]	P <sub>2</sub> O <sub>5</sub> [%]	CaO [%]	MgO [%]	Al <sub>2</sub> O <sub>3</sub> [%]
Measured	24.6±3.8	13.7±2.7	2.5±0.9	2.5±0.4	1.5±0.3	38.0±5.9	10.0±3.2	3.4±2.3
Simulated	23.8±4.9	13.8±2.9	1.9±0.5	2.5±0.5	1.3±0.5	39.2±5.0	10.1±3.9	2.9±1.5

#### 4.1.9 Valokaariuunisimulaattori

Aiemmassa luvussa käydyin Logarin ja Dovzanin valokaariuunimallin pohjalta Hay et al. (2019) ovat kehittivät valokaariuunisimulaattorin, jota voidaan käyttää hyväksi, kun koulutetaan valokaariuunioperaattoreita. Simulaattorin avulla pystytään reaaliajassa tarkastelemaan, miten ohjaus vaikuttaa uunin toimintaan. Verrattuna Logarin ja Dovzanin

malliin simulaattoriin on myös tehty lisäyksiä ja kehitetty aiempia parametreja. Esimerkkejä kehityskohteista ovat kaasufaasin mallinnus, lämpösäteilyn mallintaminen sekä kuona- ja teräsfaasin välisen vuorovaikutuksen mallintaminen. Malli on toteutettu MATLAB-ympäristössä. Kuvassa 16 on esitetty mallin rakenne ja siihen sisältyvät moduulit. Kuvasta nähdään tiedonsiirto eri moduulien välillä. (Hay et al. 2019)



Kuva 16. Mallin rakenne (mukaillen Hay et al. 2019).

#### 4.1.10 Elektrodi kulumisen mallinnus

Grafiittielektrodi kulumisen on merkittävä kuluerä valokaariuuniprosessissa. Elektrodi kulumiseen vaikuttavia tekijöitä ovat teräksen valmistukseen käytetty teknologia ja sähköiset parametrit. Elektrodi kulumisen voidaan jakaa jatkuvaan kulumiseen ja rikkoutumisesta johtuvaan elektrodi häviöön. Kun prosessia ajetaan oikeaoppisesti, 95 % kulumisesta tulisi syntyä jatkuvan kulumisen seurauksena ja 5 % muista syistä. Jatkuva kulumisen johtuu elektrodi seinämien sublimoitumisesta ja hapettumisesta. Elektrodi kärjen sublimoitumista tapahtuu vain silloin, kun uunin virrat ovat päällä ja valokaari syntyy. Tällöin elektrodi grafiitti muuttuu suoraan kiinteästä hiilestä kaasumaiseksi hiilimonoksidiksi. Sublimoitumiseen vaikuttavat elektrodi läpi kulkeva sähkövirta, valokaaren halkaisija elektrodi päässä, elektrodi resistiivisyys, valokaaren stabiilisuus ja aika. Käytettäessä korkeampaa jännitettä ja matalampaa virtaa syntyy pidempi valokaari ja tällöin myös sublimoitumisesta johtuvat häviöt pienenevät.

Yhtälössä (26) on esitetty kaava, jonka avulla voidaan määrittää grafiitin sublimoituminen tuotettua terästön kohden. (Migas & Karbowniczek 2013)

$$C_{Tip} = R_{Sub} \frac{I^2 \cdot t_{po}}{P} \quad (26)$$

missä  $C_{Tip}$  on sublimoitunut grafiitti [kg/ton],  
 $R_{Sub}$  on grafiitin sublimoitumiskerroin (kg-hr/kA<sup>2</sup>),  
 $I^2$  on virta [kA],  
 $t_{po}$  on aika, jona virta on päällä [h] ja  
 $P$  on sulatuksessa tuotetut terästönnit.

Elektrodien seinämien hapettumiseen vaikuttavat elektrodin tiheys ja resistiivisyys, kaadosta kaatoon -aika, lämpötila, virta ja kaasufaasi uunin sisällä. Hiilimonoksidikerros elektrodin ympärillä suojaa elektrodia hapettumiselta, kun taas kaikki tekijät, jotka vaikuttavat suojaavaan häikäkerrokseen nopeuttavat hapettumista. Yhtälössä (27) on esitetty hapettuvan grafiitin määrä tuotettua terästön kohden. Taulukossa 13 on esitetty muita elektrodien kulumiseen vaikuttavia tekijöitä. Taulukkoa 13 ja yhtälöä (26) vertaillen huomataan, että virralla on hyvin suuri merkitys elektrodien kulumiseen. Taulukossa on myös muita yhtäläisyyksiä yhtälöiden (26) ja (27) kanssa, kuten sulatuksen keston vaikutus elektrodien kulumiseen. (Migas & Karbowniczek 2013, Zhang 2011)

$$C_{Tip} = R_{Ox} \frac{A \cdot t_{tap}}{P} \quad (27)$$

missä  $C_{Tip}$  on hapettunut grafiitti [kg/ton],  
 $R_{Ox}$  on hapettumiskerroin [kg/m<sup>2</sup>-hr],  
 $A$  on hapettuvan elektrodin pinta-ala [m<sup>2</sup>],  
 $t_{tap}$  on kaadosta kaatoon-aika [h] ja  
 $P$  on sulatuksessa tuotetut terästönnit.

Taulukko 13. Elektrodien kulumiseen vaikuttavia tekijöitä (Zhang 2011).

<b>Factors</b>	<b>Variation of Factor</b>	<b>Variation of Unit Consumption</b>
Tapping Amount	each $\pm 1t$	$\pm 24g/t$
Steel Charging / Tapping Amount	each $\pm 1kg/t$	$\pm 5.2g/t$
Slagging Material / Tapping Amount	each $\pm 1kg/t$	$\pm 9.3g/t$
Tapping Temperature	each $\pm 1^{\circ}C$	$\pm 4g/t$
Power-off Time	each $\pm 1min$	$\pm 17g/t$
Output Power	each $\pm 1kW/t$	$\pm 5.6g/t$
Arc Current	each $\pm 1kA$	$\pm 60g/t$

#### 4.1.11 Valokaariuuniprosessin CFD-mallinnus

Laskennallinen virtausdynamiikka eli CFD on työkalu virtausten mallintamiseksi. Sen avulla saadaan selville tietoa prosessin olosuhteista ja sitä voidaan käyttää kehitystyössä. Metallurgisia prosesseja mallinnettaessa tulee ottaa huomioon niiden erityispiirteet, kuten korkea lämpötila, systeemin eri faasit ja kemiallisten reaktioiden vaikutus virtaukseen. Valokaariuunille tyypillisiä ilmiöitä ovat magnetohydrodynamiikka, savukaasujen virtaukset ja uunin kaasufaasin virtaukset. CFD-mallinnus perustuu liikemäärään, aine- ja energiataseisiin. Näiden avulla voidaan kuvata paikallisia ilmiöitä valokaariuunissa. Näiden paikallisten ilmiöiden ymmärtämisen avulla voidaan kuvata tarkemmin valokaariuuniprosessia kokonaisuudessaan. Malfan et al. (2009) julkaisussa CFD-mallin avulla tutkittiin kaasujen virtauksia, reaktioita kaasufaasissa, reaktioita kaasu- ja kiinteän faasin välillä, lämmön syntymistä virtausdynamiikan avulla ja injektointilaitteiston toimintaa. (Malfa et al. 2009)


#### 4.1.12 Valokaariuunin mallinnus fysikaalisella vesimallilla

Xin et al. (2019) tutkimuksessa valokaariuunin panostettavan romun sulamista tutkittiin vesimallin avulla. Tutkimuksen tarkoituksena oli ymmärtää paremmin romun sulamisprosessista valokaariuunissa. Koetta varten rakennettiin pienoismalli 65 tonnin valokaariuunista kokosuhteessa yhden suhde neljään. Mallissa terässula korvattiin


vedellä ja pohjasekoituksen argon tyellä. Mallissa jäällä mallinnettiin romua. Happipuhalluksesta syntyvää lämpöenergiaa simuloitiin mallissa puhaltamalla kuumaa höyryä. Elektrodeja mallissa simuloitiin kolmella lämmityssauvalla, joiden lämmitysteho oli 1100 wattia. (Xi et al. 2019)

Vaikka jään sulaminen vedeksi ja romun sulaminen valokaariuunissa ovat samankaltaisia prosesseja, niissä esiintyy eroja aineensiiroissa, lämmönsiirrossa ja sulamisreaktioissa. Kun kylmä romu panostetaan sulan teräksen päälle, romun pinnalle muodostuu teräskuori sulasta teräksestä, joka kasvaa ajan mukana maksimaaliseen paksuuteen. Romun ollessa sulassa teräksestä se hiilettyy, jolloin sen sulamispiste laskee. Kun romun pinnalla olevan hiilettyneen kerroksen sulamispiste laskee riittävästi, terässula pystyy sulattamaan sen, muodostuu uusi hiiletty kerros ja tämä prosessi toistuu. Kun terässula saavuttaa romun sulamispisteen, se pystyy sulattamaan sen nopeasti ilman hiilettymisreaktiota. Täten romun sulamisnopeus on riippuvainen lämmönsiirrosta sulasta teräksestä romuun. Vesimallissa veden lämpötila on aina suurempi kuin jään sulamispisteen, eli sulamisnopeutta kontrolloi lämmönsiirto vedestä jäähän. Tämä siis pystyi mallintamaan todellisuutta, mutta koska jään ja romun lämmönjohtavuus eroavat merkittävästi, siitä syntyisi virhettä mallissa. Kuitenkin, koska aiemmissa tutkimuksissa oli todettu, että lämmönjohtavuus ei ole merkittävä tekijä romun sulamisessa valokaariuunissa, tämä tekijä jätettiin huomioimatta. (Xi et al. 2019)

Mallilla tutkittiin, miten jään kappalekoon muutokset vaikuttivat sulamisaikaan. Kappalekoon kasvaessa sulamisaika pitenee. Myös vesi jäähtyy enemmän, kun lisätään suuren kappalekoon omaavia jääpaloja. Kuvassa 17 on esitetty kappalekoon vaikutus sulamisaikaan. Koska on todettu, että kappalekoon kasvaessa myös romun sulamisaika valokaariuunissa pitenee, voidaan olettaa, että malli kuvaa tältä osin hyvin todellisuutta. Kuvasta 17 voidaan myös todeta, että kun kappalekoko on 50x90 mm tai 90x80 mm, sulamisaika pitenee huomattavasti vähemmän kuin vertailtaessa suurempien kappalekokojen 100x130 mm ja 120x180 mm vaikutusta sulamisaikaan. Kuvassa 18 on vertailtu, miten kappaleen muoto vaikuttaa sulamisaikaan. Pallon muotoisella jäällä on pienin pinta-ala ja kuutionmuotoisella suurin. Tästä syystä pallon muotoisella jääpalalla on pienin lämpöä alentava vaikutus veteen, johon se panostetaan. Lisäksi koska pallon muotoisen jääpalan tilavuus on pienin, sen sulatukseen kuluu vähiten lämpöenergiaa. Vastaavasti kuution muotoisella jääpalalla on suurin tilavuus. Tämä tulos poikkeaa valokaariuunista saaduista tuloksista. (Xi et al. 2019)



Kuva 17. Jääkappeleen koon vaikutus sulamisaikaan (Mukaillen Xi et al. 2019).



Kuva 18. Kappalekoon vaikutus sulamisaikaan (Mukaillen Xi et al. 2019).

## 4.2 Ohjausmallit

Ohjausmallit ovat malleja millä ohjataan valokaariuuniprosessia. Mallien tarkkuuden lisäämiseksi ne käyttävät yleensä hyväksi prosessin aikana kerättyä dataa. Mallien tehokkuuden ja toiminnan kannalta laadukas data on erityisen tärkeää.

### 4.2.1 Dynaaminen mallinnus valokaariuuniprosessille

Dynaamisen eli ajan mukana muuttuvien mallien kehitys on ollut 2000-luvulla suosittua, koska on haluttu saada tarkempaa tietoa valokaariuuniprosessin etenemisestä sulatuksen



aikana. Dynaamisten mallien avulla prosessia voidaan simuloida, jotta saataisiin aine- ja energiataseita parempi kuvaus prosessista. Dynaamisen mallin luominen ja tarkastelu offline-ympäristössä vaatii kattavan prosessimallin ja kyvyn ekstrapoloida. Dynaamisten ohjausjärjestelmien käyttö ei ole ennen ollut mahdollista hyvin rajoittuneiden mittausten vuoksi. Esimerkiksi jatkuvatoimisten savukaasun mittauslaitteiden avulla prosessista saadaan reaaliaikaista tietoa, jota voidaan hyödyntää prosessinohjauksessa. Dynaamisen ohjauksen tarkoituksena on parantaa sulatusprosessin tehokkuutta ja parantaa sen kannattavuutta. Dynaamisten mallien tarkoitus ei ole korvata perinteistä ohjausjärjestelmää, vaan toimia sen tukena. (Echterhof et al. 2018)

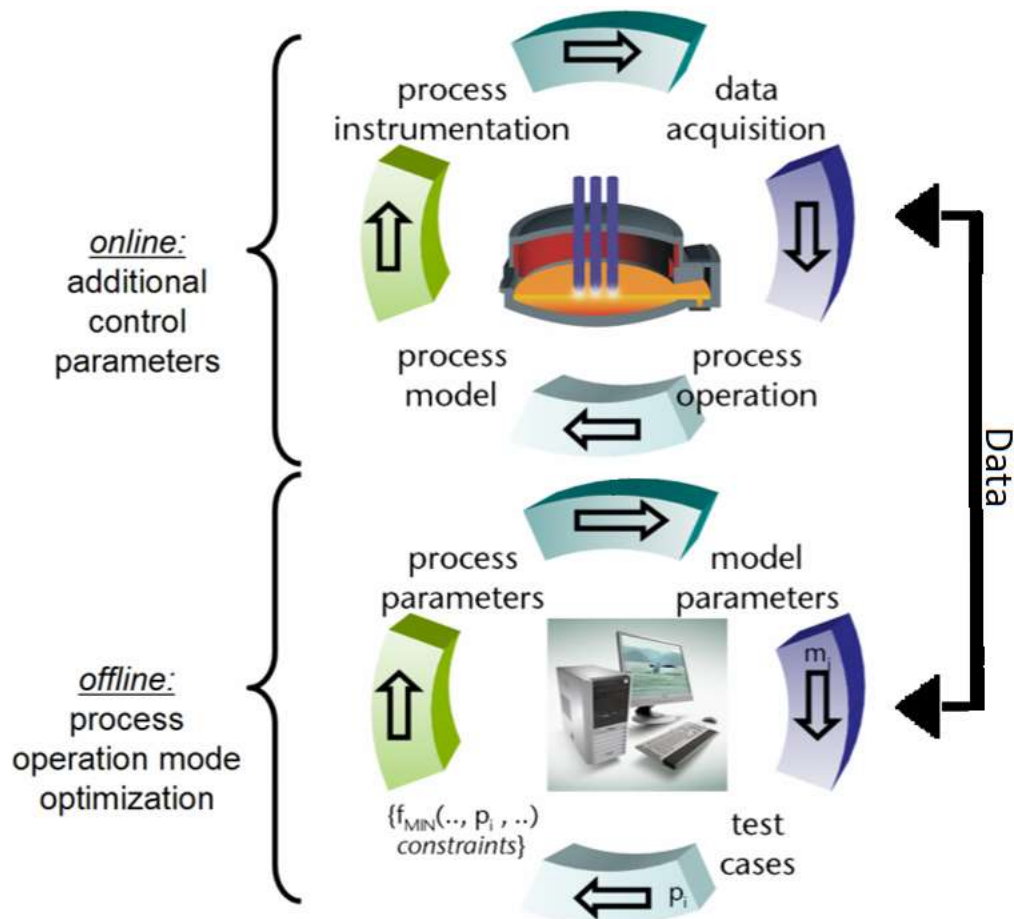
#### 4.2.2 2-tason mallit valokaariuunille PRM

Valtaosassa valokaariuuneista käytetään hyväksi tason 2 automaatiojärjestelmää. Tason 2 automaatiojärjestelmällä tarkoitetaan järjestelmää, joka käyttää hyväksi reaaliaikaista dataa ja etukäteen laskettuja arvoja, kuten uunin panoksen koostumusta. Automaatiojärjestelmät tarvitsevat toimiakseen mallin prosessista. Kehitetyt mallit ovat uuni- tai jopa terässulattokohtaisia. Valokaariuuneissa käytettävät säätö- ja mittauslaitteet mahdollistavat kvantitatiiviset ajasta riippuvat mittaukset uunin energia- ja ainetaseelle. Saatua dataa voidaan käyttää joko on-line- tai offline-mallinnukseen sulatusprosessista. On-line-mallinnusta käytetään prosessin ohjaamiseen ja offline-mallinnusta prosessin optimointiin. Mallit ovat kehittyneet kuvaamaan eri asioita prosessissa. Esimerkkeinä näistä ovat savukaasujen CFD-mallinnus ja lämmönsiirto uunin sisällä, teräksen ja kuonan sulamisprosessin mallinnus ja koko prosessin kuvaus ja prosessinohjaus. Tyypillisesti mallit perustuvat energian säilymislakiin, epälineaaristen differentiaaliyhtälöiden luontiin ja ratkaisuun sekä prosessista saatavaan ajasta riippuvaan dataan, kuten prosessiin syötettävän sähköenergian määrään. Johtuen vaikeista olosuhteista valokaariuuniprosessissa mittaaminen sulatuksen aikana on hyvin haastavaa, esimerkiksi kiinteän ja sulan materiaalin lämpötilan mittaaminen on haastavaa, kuten myös sulan teräksen massan mittaaminen prosessin edetessä. On-line-prosessimalleilla voidaan parantaa tietämystä prosessista ja täten kehittää prosessia saadun datan perusteella. (Wendelstorf et al. 2006)

Wendelstorfin et al. (2006) Process Reactor Model kehitettiin kuvaamaan metallurgisia ilmiöitä, ja sen avulla on mahdollista kuvata valokaariuunin toimintaa. Mallia on mahdollista hyödyntää offline- ja on-line-ympäristöissä, ja se on mahdollista integroida terästehtaan valmiiseen 2-tason automaatiojärjestelmään. Mallin avulla on mahdollista

laskea esimerkiksi sulan lämpötila prosessin aikana. Laskenta perustuu tietoihin prosessiin panostettavista materiaaleista ja mitattuihin tai ekstrapoloituihin arvoihin prosessin aikana. Energia- ja ainetase ratkaistaan mallissa ajasta riippuvaisina termeinä. Panosmateriaalit, terässula, kuona ja uunin rakenne mallinnetaan yhdessä savukaasun massa- ja energiavirtojen kanssa. Mittauslaitteiden kehittyessä on mahdollista saada prosessista entistä parempaa dataa, jonka avulla mallia pystytään kehittämään ja saamaan tarkempia tuloksia. (Wendelstorf et al. 2006)

Wendelstorfin et al. (2006) mukaan valokaariuunin mallia laadittaessa valokaariuuniprosessia tulee analysoida ja selvittää parametreja prosessin syötteestä ja ulostulosta. Prosessista tulee kartoittaa noin 20 ajasta riippuvaa tekijää, kuten valokaaren teho, sekä lisäksi noin 20 prosessiparametria, kuten uunin pinta-ala ja noin 20 ulostuloarvoa, kuten sulan paino ja lämpötila. Lisäksi useita muita termejä, jotka liittyvät prosessin hallintaan, kuten energian jakautumista kuvaava termi. Lisäksi tulee määrittää prosessin tasapainoa kuvaavat ominaisuudet, joita ovat esimerkiksi energiatase lämpötilan keskiarvon laskemiseksi, kierrätysteräksen ja muiden hiiltä sisältävien panosmateriaalien aine-, energia- ja hiilitaseen määrittäminen sekä kuonan ja savukaasujen aine- ja energiataseet. Lisäksi tulee määrittää yhtälöt, joiden avulla aineen- ja energiansiirtoa seurataan faasien välillä. Tämän jälkeen suoritetaan datan hankinta ja siistiminen käytettävään muotoon sekä mallin testaaminen datan avulla ja sen käyttöönotto teollisuudessa. Viimeiseksi mallin avulla pyritään parantamaan valokaariuuniprosessia aluksi keräämällä dataa offline-mallilla, jonka jälkeen saatua dataa käytetään on-line-ympäristössä prosessin parantamiseksi kuvassa 19 esitetyllä tavalla. (Wendelstorf et al. 2006)



Kuva 19. Process Reactor Modelin käyttö teollisuudessa (mukaillen Wendelstorf et al. 2006).

Määritellyssä mallissa kuvataan sähköenergiaa, kemiallista energiaa, prosessiin panostettavia materiaaleja, häviöitä ja savukaasuja. Sähköenergian käyttöä eli valokaaren tehoa kuvataan jokaisella aika-askeleella, ja lisäksi tarkastellaan yhtäaikaisesti energiankäytön jakautumista kiinteään, sulaan ja kaasufaasiin. Kemiallisen energian syöttöä prosessiin määritetään ajasta riippuvana vakiona ja sitä, kuinka se jakautuu eri faaseihin. Jos prosessin aikana panostetaan toinen romukori tai uuniin syötetään muulla tavalla lisää materiaalia ajasta riippuvana vakiona, selvitetään näille materiaaleille aine-, energia- ja hiilitasapaino, kuten aiemmin on mainittu. Prosessin aikana tapahtuvat häviöt, kuten säteilystä ja konvektiosta johtuvat, mallinnetaan lämmönsiirtotermien avulla. Uunin kaasufaasi mallinnetaan prosessissa olettamalla, että kaasufaasin massa uunin sisällä ei muutu ja sisään- ja ulosvuotoilmaparametrien avulla. (Wendelstorf et al. 2006)

### 4.2.3 Siemens VAI SteelExpert

Siemens VAI on kehittänyt ryhmän prosessimalleja, jotka kuvaavat valokaariuunin toimintaa. Näitä moduuleita yhdessä kutsutaan SteelExpert-tuotteeksi. SteelExpert toimii valokaariuuniprosessissa tason 2 automaatiojärjestelmänä. Moduuli koostuu SteelExpert Chargesta, SteelExpert Predictionista ja SteelExpert Supervisionista. SteelExpert Charge-moduuli laskee panoksen valokaariuunille sillä perusteella, mitkä halutun terässulan koostumus ja paino ovat. Laskennan rajoitteeksi voidaan asettaa ennalta määrättyjä arvoja, kuten maksimi- ja minimimäärä tiettyä materiaalia, kiinteitä materiaalmääriä teräslajeille, maksimi- ja minimisuhteita eri materiaaleille, lastausjärjestys romukoria lastattaessa ja materiaalien jakautuminen romukorien välillä useamman korin panostusta käytettäessä. SteelExpert Predictions -moduuli simuloi sulatuksen alusta loppuun Chargesta saatujen tietojen perusteella ja lisäksi tekee lisäyksiä prosessissa tapahtuvien syötteiden, kuten polttimien käytön perusteella. Myös Predictions-moduuliin pystytään syöttämään kiinnitettyjä arvoja, kuten paljonko energiaa tulee olla syötetty prosessiin ennen toisen korin panostusta. SteelExpert Supervision on prosessia seuraava on-line-malli, joka seuraa laskennallisesti massaa, lämpötilaa ja analysoi sulaa. Moduuli seuraa uunissa tapahtuvia todellisia ja laskennallisia ilmiöitä. (Natschläger & Stohl 2007)

### 4.2.4 Panostusmallit

Tällä hetkellä suurin rajoittava tekijä valokaariuunin prosessimalleja luotaessa on suuret vaihtelut panosmateriaalien ominaisuuksissa. Erityisesti kierrätysromun ominaisuuksien määrittäminen tarkasti on mahdotonta. Teoreettisissa malleissa ongelma on tarve tietää panosmateriaalien tarkat ominaisuudet, kuten koko ja kemiallinen koostumus. Tehtäessä oletuksia panosmateriaalista poikkeamat todellisuudesta luovat virheitä todellisuuden ja mallinnetun välillä. Empiirisiä malleja luotaessa ei ole tarvetta tietää tarkkoja ominaisuuksia, koska ne perustuvat mitattuihin arvoihin. Kuitenkin myös empiirisissä malleissa ongelmaksi nousevat vaihtelut romun ominaisuuksissa. Tätä virhettä voidaan korjata uudelleensovittamalla malli, kun tiedetään panosmateriaalien muuttumisesta. (Sandberg 2005)

Romun ominaisuuksia voidaan määrittää tutkimalla sulatuksen lopussa saatuja tietoja. Terässulan näytteestä saadaan selville sen lopullinen kemiallinen koostumus, sähköenergian käytöstä voidaan määrittää käytetty energia romu- ja terästonnin kohden

ja panostus- ja loppupainon perusteella saanti. Näiden tekijöiden avulla voidaan luoda regressiomalleja, joiden avulla voidaan määrittää romun ominaisuuksia. (Sandberg 2005)

Terästehtailla on käytössä panostusmalleja, joiden avulla pyritään määrittämään halvin mahdollinen terässula, joka täyttää laatuvaatimukset. Riippuen tehtaasta mallit voivat olla hyvin yksinkertaisia tai monimutkaisia. Yksinkertaisin ratkaisu on luoda muutama yksinkertainen panostusresepti, joka ottaa huomioon romun hinnan, tilavuusrajoitukset uunissa ja romukorissa sekä terässulalta halutun kemiallisen koostumuksen. Toinen tapa määrittää panos on ottaa huomioon energiankulutus ja metallin saanti. Tällöin tulee ottaa eri panosmateriaalien ominaisuudet ja laskea niiden sulattamiseksi vaadittu energia. Samalla tulee ottaa huomioon, kuinka eri tavalla uuniin syötetty energia vaikuttaa panokseen; esimerkiksi happipuhallus vaikuttaa eri tavalla kuin happi-kaasupolttimet. Valtaosa panostusmalleista on dynaamisia eli ne ottavat huomioon vaihtelut kierrätysromun ominaisuuksissa. Malleja päivitetään, kun romuntoimittaja vaihtuu tai romuntoimittaja kertoo romun koostumuksen muutoksista. Päivityksiä tehdään, jos sulatustiedot antavat kuvan, että romun ominaisuuksissa on todennäköisesti tapahtunut muutoksia. Siemensin SteelExpert Chargessa on mahdollista asettaa panoslaskentaan määriteltäviä arvoja, joiden tulee täyttyä. Esimerkiksi kahden korin sulatuksissa voidaan määrittää, kuinka suuri osa panoksesta tulee olla korissa yksi ja kuinka suuri osa korissa kaksi. Myös kun tiedetään romun ominaisuuksia, voidaan määrittää, missä järjestyksessä kori tulee lastata, esimerkiksi kappaleiden painon perusteella. (Natschläger & Stohl 2007, Sandberg 2005)


### 4.3 Mallien yhteenveto

Lähes jokaisessa tässä luvussa läpikäydyistä julkaisuista, joissa mallit oli esitelty alkusanoissa, mainittiin halu vähentää sähkönkulutusta tai tehostaa raaka-aineiden käyttöä. Kirjallisuudesta löytyi paljon eri malleja, mutta suurimmassa osassa julkaisuista niiden toimintaperiaatteet ja tarkkuus oli esitetty hyvin pintapuolisesti. Esimerkiksi mallin tarkkuutta oli usein kuvattu korkeintaan sanoilla hyvä tai erinomainen. Mallit myös kuvasivat eri asioita: osa kuvasi koko prosessia ja toiset vain yhtä prosessin osaa tai ilmiötä. Tutkittaessa, millaisia malleja teollisuudessa voitaisiin käyttää, tulisi aluksi määrittää, mitä halutaan tutkia ja millaisten mallien avulla tämä on mahdollista. Malleja tutkittaessa tulee myös ottaa huomioon valokaariuunin erilaisuudet ja miten esimerkiksi hiiliterästen ja ruostumattoman teräksen tuottaminen vaikuttaa malleihin. Kehittäessä

malleja tulee muistaa, että kun malli kehitetään juuri tietyille valokaariuunille, tulokset ovat todennäköisesti parempia kuin käytettäessä yleisesti valokaariuuneille tuotettua mallia. Vaikka tässä luvussa käydyt mallit ovatkin vain pieni osa kehitetyistä malleista valokaariuuniprosesseille, niin niistä silti saa hyvän käsityksen siitä, mitä malleilla pystytään mallintamaan, mitkä mallien puutteet yleensä ovat, mitä mallien kehityksessä tulee ottaa huomioon ja millaisia eri lähestymistapoja mallien kehitykseen on olemassa. Julkaisujen vuosiluvuista myös saa hyvän kuvan siitä, milloin tiettyä mallinnustapaa on hyödynnetty laajemmin.

## 5 VKU2-PROSESSIMALLIT

Luvussa käydään läpi linja 2:lla ja VKU2:lla käytössä olevia malleja ja niiden toimintaperiaatteita. Mallit voidaan jakaa prosessia ohjaaviin ja prosessista tietoa tuottaviin. Outokummun 1-tason automaatiosta vastaa Honeywellin järjestelmä, jonka rinnalla 1-tasossa toimivat DynArCOS, ArCOS ja BSE:n polttimienohjausjärjestelmä. 2-tason automaatiosta vastaa VAI:n toimittama järjestelmä, johon on lisätty Outokummun itse kehittämienä moduuleina esilaskenta ja erilaisia prosessimalleja. Prosessin etenemistä raaka-ainepihan ja sulaton osalta seuraa ValuA, joka toimii sulaton järjestelmässä 3-tasossa. 3-tasossa toimii myös yleinen tietokanta Qmato. Edellä mainitut mallit ohjaavat ja seuraavat sulattoprosessia. Lisäksi on käytössä malleja, jotka eivät vastaa itse prosessin ohjauksesta. Paukkua käytetään terässulatolla panoksen laskemiseen, mutta se ei itsessään vaikuta prosessin ohjaukseen. MORSEVKU2-malli, sulatusajan optimointimalli, elektrodien kulumismalli ja 2-tason prosessimallit ovat käytössä sulatolla, jotta prosessia ymmärrettäisiin paremmin. Paukku-panoslaskennan tapaan nämäkään eivät itse vaikuta prosessin ohjaukseen. Jos jokin näistä neljästä mallista kuitenkin todetaan toimivaksi, on niistä saatavia tietoja mahdollista käyttää prosessinohjaamiseen. Kuvassa 20 on esitetty mallien käyttöalueet valokaariuuniprosessissa.



Kuva 20. Mallien käyttöalueet valokaariuuniprosessissa.

## **5.1 Mistä mallit saavat tarvittavat tiedot**

### **5.1.1 Tasesulatukset**

Tasesulatusten avulla määritellään koostumus kierrätysteräserälle. Tasesulatusten panos sisältää ainoastaan yhtä kierrätysteräserää ja muita tunnettuja raaka-aineita, kuten ferrokromia ja ferropiitä. Sulatuksista tehtyjen analyysien perusteella saadaan selville romuerän koostumus ja määritetään sille hinta. Mahdollisimman tarkan tuloksen saamiseksi tasesulatukset tehdään ilman keskeytyksiä ja mahdollisimman samankaltaisella sulatuspraktiikalla. (Hyttinen 2020)

### **5.1.2 Savukaasujen analysointi**

VKU2:lla on ollut ennen käytössä savukaasuanalysaattori, jolla on saatu tietoa prosessin aikana esimerkiksi savukaasun hiilimonoksidi-, hiilidioksidi-, happi-, typpi- ja argonpitoisuuksista. Näiden tietojen avulla on pystytty määrittämään esimerkiksi, milloin pii loppuu terässulasta ja kromin voimakkaampi hapettuminen alkaa. Näytteenottosondi on sijainnut primäärikanavan päällä, ja se on ollut ruostumattomasta teräksestä valmistettu vesijäähdytetty putki. Hasan (2016) diplomityössä suurimmiksi ongelmiksi savukaasuanalysaattorin käytössä on muodostunut näytesondien tukkeutuminen ja analysointilinjan vuodot. Suurimmaksi syyksi tukkeutumiselle on esitetty uuniin injektoitava kalkki. Lisäksi automaatiojärjestelmään asennettu savukaasuanalysaattorin näytteenotto-ohjelma on häirinnyt elektrodien vesijäähdytyksen automaatio-ohjelmaa, minkä seurauksena se on poistettu käytöstä. Jos savukaasuanalysaattori saataisiin toimimaan luotettavasti, sen avulla kerättyjen tietojen perusteella olisi mahdollista kehittää käytettäviä valokaariuunimalleja entistä tarkemmaksi. Erityisesti reaaliajassa saatava tieto parantaisi mallien tarkkuutta merkittävästi. (Hasa 2016, Oinas 2009)

### **5.1.3 Qmato**

Qmato on terässulaton ja kuumavalssaamon yhteinen tuotannonohjausjärjestelmä, joka toimii 3-tasossa. Sen tietokannassa sijaitsevat tiedot kaikista sulatuksista terässulatolla, ja esimerkiksi Paukku saa tiedot Qmadosta. Qmatoon on myös sisällytetty tiedot käytettävissä olevista raaka-aineista ja niiden koostumuksista.



#### 5.1.4 Analyysit

Kun terässula on kaadettu valokaariuunista senkkaan, siitä otetaan näyte ja mitataan lämpötila. Joka sulatuksesta otetaan teräsnäyte, jota kutsutaan 7-näytteeksi ja kuonanäyte, jota kutsutaan 707-näytteeksi. Näytteet lähetetään putkipostia pitkin laboratorioon, jossa ne analysoidaan. Lämpötilanmittaus terässulasta suoritetaan kertakäyttöisten termoparianturien avulla. On otettava huomioon, että tässä vaiheessa terässula on jo ehtinyt jäähtyä sulatuksen lopetushetkestä hieman. Valmistuneet analyysit lähetetään Qmatoon.

#### 5.1.5 Mittalaitteet

Kun terässula on kaadettu senkkaan, sen kaatopaino saadaan selville senkkavaunun puntarin avulla. Tämä arvo voidaan todentaa nosturin puntarin avulla, kun sula panostetaan AOD:lle. Qmadossa oleva kaatopaino on määritetty nosturin puntarin avulla. Uunin jäähdytysvesien lähtö- ja paluulämpötiloja mitataan, jotta saadaan tietoa siitä, paljonko valokaaret ja sula lämmittävät vuorausta sekä uunin rakennetta. Vaikka savukaasuja ei analysoida, niiden lämpötilaa mitataan prosessin aikana.

### 5.2 Panoslaskenta


#### 5.2.1 Paukku

Paukku laskee panoksen sulatukselle. Tiedot halutusta sulan loppukoostumuksesta Paukku saa Qmadosta, ja panoslaskennan valmistuttua se lähettää lasketun panoksen tiedot takaisin Qmatoon. Panoslaskenta toimii kustannusfunktion periaatteella. Kaikille panosmateriaaleille on määritetty kemiallinen koostumus ja hinta. Panoslaskenta ottaa huomioon valokaariuunin lisäksi muut prosessivaiheet ja näiden perusteella luo kustannusfunktion. Kustannusfunktion ratkaisee IBM:n ohjelmisto CPLEX. Tavoitteena on siis saavuttaa haluttu kemiallinen koostumus sulalle mahdollisimman halvalla. Laskettu panos ei kuitenkaan toteudu itse romukoreissa, koska niiden lastaaminen täydellisesti ei ole mahdollista. Tästä syystä ennen sulatuksen aloitusta esilaskenta määrittää toteutuneen panoksen perusteella, mitä aineita sulatuksen aikana tulee lisätä. Lisäksi Paukussa on mahdollista määrittää manuaalisesti kiinteitä arvoja, joita panoksen tulee toteuttaa. Esimerkiksi tietyille teräslajille voidaan määrittää, että määrätyn raaka-aineen käyttö on sitä valmistettaessa pakollista. (Auer 2020)

Paukkua voidaan verrata luvussa 4.2.3 läpikäytyyn Charge-moduuliin. Voidaan olettaa, että Paukku on kehitetty versio Chargesta ruostumattoman teräksen valmistukseen. Lisäksi luvussa 4.2.4 käydyissä panostusmalleissa on samankaltaisuuksia verrattaessa Paukun toimintaa. Luvussa mainitaan, että terästehtailla on käytössä panosmalleja, joiden tarkoituksena on määrittää halvin mahdollinen panos tietyn koostumuksen täyttämiseksi, minkä perusteella myös aiemmin mainittu kustannusfunktio toimii.

### 5.2.2 SulO

SulO määrittää tasesulatusten avulla romuerien kemiallisen koostumuksen. Lisäksi SulO itseoppii lisää sulatusten kemiallisista koostumuksista. Itseoppiminen perustuu ennustettuun ja todelliseen sulan koostumukseen. Hotcirclessä eli terässulatun ja kuumavalssaamon intranet-sivulla on raaka-ainekulutusten online-seurantamonitori, josta on mahdollista tarkastella sulatuskohtaisesti panoslaskennassa lasketun kromi- ja nikkelpitoisuuden toteutumista 7-näytteessä. Kuvassa 21 on esitetty Hotcirclessä oleva online-kuvaaja, joka seuraa kromi- ja nikkelpitoisuutta VKU2:n osalta. (Auer 2020)



Kuva 21. Paukun laskema koostumus ja toteutunut koostumus nikkelille ja kromille.

SulO:n avulla siis pyritään tehostamaan Paukun toimintaa tuottamalla laadukkaampaa dataa raaka-aineista, mikä on mainittu myös luvussa 4.2.4 osana tehokkaampien panoslaskenta-mallien kehitystä. Luvussa 4.1.7 mainitaan, että raaka-aineiden hinnat vaihtelevat, ja tämä vaihtelu vaikuttaa siihen, millainen panos on optimaalisin hallitsevassa markkinatilanteessa.

### 5.3 2-tason automaatiojärjestelmä VKU2:lla

Valokaariuunin 2-tasosta vastaa VAI:n vuonna 2002 toimittama 2-tason automaatiojärjestelmä, jolla on joitain yhtäläisyyksiä luvussa 4.2.3 esitetyn SteelExpertin kanssa. SteelExpertin mallit on kuitenkin kehitetty hiiliteräksen valmistukseen, minkä seurauksena niiden hyödyntäminen ruostumattoman teräksen valmistuksessa sellaisenaan on mahdotonta. VAI:n toimittaman järjestelmän ympärille Outokummulla on itse kehitetty prosessimalleja.

#### 5.3.1 Esilaskenta

Esilaskentaohjelmistoa käytetään uunin saannon ja ohjattavuuden parantamiseksi. Panoslaskennassa laskettua panosta ei saada lastattua koriin niin, että se olisi juuri sama kuin laskennan määrittämä koostumus. Kun romukori on lastattu ja tiedetään toteutunut panos, voidaan korvata toteutuneen ja lasketun panoksen eroavaisuuksia 2-tason esilaskennalla. Itse panoslaskentamalli on sama esilaskennalla ja Paukulla. Kun panoksesta saadaan tieto esilaskentaan ennen sulatuksen aloitusta, on operaattorilla mahdollista tehdä muutoksia uunin ajotapaan, jos se nähdään tarpeelliseksi. Muutoksiin vaikuttavat panoksen lisäksi edellisistä sulatuksista saadut tiedot. Näin onnistutaan pienentämään sulatusten välistä hajontaa. (Auer 2020, Roininen et al. 2008)

Ensimmäiseksi esilaskenta laskee panoksen piimäärän. Piimäärällä on suuri vaikutus siihen, kuinka suuri osa kromista hapettuu kuonaan. Laskemalla panoksen kaikkien piitä sisältävien materiaalien piipitoisuudet yhteen saadaan selville panoksen piimäärä. Seuraavaksi määritetään sulatuksen kokonaiskesto, joka vaikuttaa merkittävästi siihen, paljonko piitä tarvitaan suojaamaan kromia hapettumiselta. Sulatuksen kesto arvioidaan panoksen massan, uunin sulatustehon ja lisäajan perusteella. Lisäajalla tarkoitetaan esimerkiksi seuraavien prosessivaiheiden odotusta. Kun tiedetään uunin päälläoloaika ja piin palamisnopeus, voidaan laskea, paljonko piitä palaa prosessin aikana. Roinisen et al. (2008) raportissa on arvioitu piin palamisnopeuden olevan noin 24 kg/min, kun tehot uunissa ovat päällä. Lisäksi haponkestäviä laatuja valmistettaessa esilaskenta ottaa huomioon molybdeenin vaikutuksen piin palamiseen, koska molybdeeni sisältää happea, joka polttaa panoksessa olevaa piitä. Panoksen piimäärän ja tavoiteltavan kuonan emäksisyyden perusteella lasketaan lisättävän kalsiumoksidin määrä. (Roininen et al. 2008)

## 5.4 2-tason prosessimallit

2-tason prosessimallit on kehitetty toimimaan VAI:n 2-tason rinnalla. Mikään näistä malleista ei ole tietävästi aktiivisessa käytössä, mutta ne pyörivät automaattisesti taustalla Qmadossa. Sulatuksen aikana mallit on jaettu kuuteen vaiheeseen: sulatukseen ensimmäisestä romukorista viimeisen romukoriin, seostukseen sulatuksen aikana, raffinointiin, pelkistykseen, kaatoon ja uuden panoksen odotukseen. Taulukossa 14 on esitetty mallit ja niiden selitykset. Malleihin syötetään mitattuja, laskettuja ja oletusarvoja, ja tuloksena saadaan mallin laskemat arvot. Mallien parametrit voidaan jakaa fysikaalisiin ja kemiallisiin vakioihin, numeerisiin parametreihin, sulattokohtaisiin sekä mallien omiin parametreihin. Näistä sulattokohtaiset ja mallien parametrit on varastoitu tietokantaan, joita muuttamalla voidaan vaikuttaa mallien toimintaan. Muut parametrit on kovakoodattu tietokantaan, koska niiden muuttamiselle ei ole nähty tarvetta. (Arzt 2004)

Taulukko 14. 2- tason prosessimallit ja niiden selitykset.

Prosessimallit ja niiden osat	Selitykset
Teräs- ja kuonalaskenta	Laskee teräksen ja kuonan koostumuksen materiaalien lisäämisen jälkeen
Energiamalli	
<ul style="list-style-type: none"> <li>• Korin sulatus</li> <li>• Ei-syklinen malli</li> <li>• Syklinen laskenta</li> </ul>	<ul style="list-style-type: none"> <li>• Kuinka paljon energiaa tarvitaan romukorin sisällön sulatukseen</li> <li>• Päivittää energiatasetta prosessivaiheen perusteella</li> <li>• Jatkuva energiatase laskenta</li> </ul>
Seostusmalli	Kuinka paljon seosaineita tulee panostaa, jotta päästään haluttuun teräksen loppukoostumukseen
Kuonamalli	Kuinka paljon kuonanmuodostajia tulee panostaa, jotta päästään haluttuun kuonan loppukoostumukseen
Raffinointimalli	
<ul style="list-style-type: none"> <li>• Hapen asetusarvo malli</li> <li>• Syklinen O<sub>2</sub>-malli</li> </ul>	<ul style="list-style-type: none"> <li>• Laskee, kuinka paljon happea tulee syöttää systeemiin, jotta saavutetaan haluttu piimäärä</li> <li>• Jatkuva hapen jakautumisen laskenta syötetyn happimäärän perusteella</li> </ul>

#### 5.4.1 Mallien toiminta ennen sulatusta ja sen aikana

Prosessimallien toiminta alkaa, kun 2-tason systeemi saa tiedon, millainen panos sulatukseen on tulossa. Tämän tiedon perusteella 2-tason esilaskenta määrittää aine- ja energiataseen sekä laskee, paljonko energiaa tarvitaan sulattamaan panos. Lisäksi esilaskenta määrittää, kuinka paljon materiaalia tulee panostaa sulatuksen aikana, jotta päästään haluttuun loppupainoon ja -koostumukseen. Energiamalli määrittää energiataseen sulatukselle perustuen tietoihin, mitä se saa panoksesta. Lisäksi se määrittää tarvittavan energian jokaiselle romukorille ja paljonko energiaa tarvitaan, jotta sula saadaan lämmitettyä haluttuun lämpötilaan. Teräs- ja kuonalaskenta määrittelevät, paljonko terästä ja kuonaa syntyy romukoreihin lastatusta materiaalista. Näiden tietojen avulla seostusmalli laskee, kuinka paljon seosaineita tulee lisätä, jotta päästään haluttuun lopputulokseen. Seostusmallin määritettyä lisättävät seosaineet teräs- ja kuonamalli

määrittää uuden loppukoostumuksen teräkselle ja kuonalle. Tämän laskennan tuloksen perusteella raffinointimalli laskee, paljonko sulaan tulee puhalttaa happea, jotta päästää haluttuun piipitoisuuteen. Viimeiseksi kuonamalli laskee edeltävien tietojen perusteella, paljonko sulatuksen aikana tulee lisätä kuonanmuodostajia. Tämä kaikki laskenta tapahtuu ennen kuin romu on panostettu uuniin. (Arzt 2004)

Kun romukori on panostettu uuniin, energiamallin syklinen laskenta alkaa laskea uunin lämpötilaa ja jatkaa laskentaa sulatuksen loppuun asti. Kun uuniin panostetaan lisää materiaalia, teräs- ja kuonalaskenta käynnistyy automaattisesti, ja energiamalli päivittyy lisättävien materiaalien ja niiden määrien perusteella. (Arzt 2004)

### **5.4.2 Energiamalli**

Laajimmin tutkittu malli näistä prosessimalleista on energiamalli. Karassaaren (2008) diplomityössä on pyritty kehittämään tätä mallia ja mallintamaan kaatolämpötilaa dynaamista energiatasetta apuna käyttäen. Tavoitteena on ollut määrittää paremmin sulatuksen lopetusajankohta ja säästää kustannuksissa energiaa vähentämällä. Mallin suurimpana ongelmana on se, että romuteräksen lämpösisältö on oletettu vakioksi. Tästä syystä malli ei ole riittävän tarkka. Mallin tarkkuutta voitaisiin kehittää merkittävästi lisäämällä automaattisesti päivittyvä entalpia jokaiselle sulatukselle tai romuerälle erikseen. (Karassaari 2008)

## **5.5 Sulatusajan optimointimalli**


Sulatusajan optimointimalli on Microsoftin VKU2:lle kehittämä prosessimalli, jonka tavoitteena on vähentää vaihtelua teräksen kaatolämpötilassa ja kaatopainossa. Tällöin sulan teräksen lämpötilan tulee olla 1580-1620 °C ja kaatopainon tulee olla lähellä tavoitetta. Mallia luotaessa sulat jaoteltiin kaatolämpötilan mukaan alilämpöisiin, ylilämpöisiin ja optimilämpöisiin. Kun tarkasteltiin jakautumista 8009 sulatuksen osalta, saatiin selville, että tyypillisesti energiaa käytetään 59-64 MWh, panospaino on 150-170 tonnia ja kaatolämpötila 1600-1630 °C. Optimilämpöisiä sulatuksista oli 69,6 %, alilämpöisiä 16,1 % ja ylilämpöisiä 14,3 %. Lisäksi sulatuksen edetessä seurattiin THD:ta eli säröä. Tällä tarkoitetaan valokaariuunissa sähköisiä häiriöitä, kuten valokaaren

epästabiilisuutta. Koska THD vaimenee sulatuksen edetessä, sen avulla voidaan arvioida, kuinka suuri osa panoksesta on sulanut. (Thampi 2019)

Ennen mallin luontia määritettiin, miten eri tekijät vaikuttavat energiantarpeeseen prosessissa aiempien sulatusten perusteella. Tarkasteltaessa käytettyä energiaa ja sulien kaatolämpötilaa huomattiin, että alilämpöisiin suliiin käytettiin vähemmän energiaa kuin ylilämpöisiin. Aiemman sulatuksen vaikutuksesta huomattiin, että jos edellinen sulatus oli alilämpöinen, seuraavaan sulatukseen käytettiin enemmän energiaa. Myös panospainolla oli vahva korrelaatio käytettyyn energiaan eli panospainon kasvaessa energiankäyttö kasvoi. Outokummun Tornion tehtaan sijainnin vuoksi vuodenajoilla on suuri merkitys käytettyyn energiamäärään. Kylmimpinä kuukausina käytetään selvästi enemmän energiaa kuin lämpiminä. Uunin vuorauksen tila vaikuttaa myös energian tarpeeseen. Erityisesti vasta uusittu vuoraus kasvattaa energian tarvetta merkittävästi, mutta tämä lisätarve tasoittuu ensimmäisen kymmenen sulatuksen jälkeen. Vuorauksen iän kasvaessa käytetyn energian tarve romun sulattamiseen vähenee. Liitteessä 2 on esitetty mallin luonnissa käytettyjä parametreja. (Thampi 2019)

Mallin pohjana oli 5510 optimilämpöistä sulatusta, jotka jaettiin 3860 sulatuksen opetusjoukkoon ja 1650 sulatuksen testausjoukkoon. Loput ali- ja ylilämpöiset jätettiin sokkotestiin, jolloin pystyttiin kokeilemaan, suositteleeke malli alilämpöisille lisää energiaa ja ylilämpöisille vähemmän energiaa. Koulutus algoritmeja mallissa olivat lineaarinen regressio, päätöspuuregressio, Random Forest ja Gradient Boosted Trees. Kaatolämpötila- ja kaatopainomallia validoitaessa Random Forest suoriutui parhaiten. Kuvassa 22 on esitetty sulatusajan optimointimallin demonäkymä, joka on tarkoitettu operaattorien käytettäväksi. Näkymässä näkyvät teräslaji, sulatusnumero, energiantarve tuotettua terästönä kohden, ennustettu kaatolämpötila ja ennustettu paino. Vihreän pohjan muuttuessa punaiseksi malli viestii, että sen perusteella sulatus tulisi lopettaa. Lisäksi liitteessä 3 on esitetty näkymästä löytyvät historiatiedot aiemmille sulatuksille. Historiatiedoissa näkyvät ennustettu ja toteutunut energiantarve, kaatolämpötila ja kaatopaino. Lisäksi mallista on saatavilla huomattavasti lisää dataa, joka on tarkoitettu insinöörien käyttöön Power BI-ympäristössä. (Thampi 2019)

## Tehot päälle/Tehot pois



Kuva 22. Sulatusajan optimointimallin demonäkymä.

Malli koostuu kaatolämpötila-, kaatopaino-, energia- ja ylijäämämallista. Ylijäämämalli arvioi muiden mallien avulla, onko koko panos sulanut. Jos mallin mielestä koko panos ei ole sulanut, tämän jälkeen muut mallit suorittavat mallinnuksen uudestaan. Tämä toistuu, kunnes mallin mielestä panos on sulanut kokonaan. (Hytinen 2020)


Sulatusajan optimointimallia voidaan verrata luvussa 4.1.5 esitettyihin neuroverkkomalleihin. Luvussa mainittu Gajicin et al. malli perustuu kierrätysromun kemialliseen koostumukseen eli mallintamisen perusteet eroavat merkittävästi sulatusajan optimointimallista. Lisäksi mallin kehittämiseen käytetty data on 46 sulatuksesta verrattuna sulatusajan optimointimallin mallin 8009 sulatuksen dataan.

### 5.6 MORSEVKU2

Osana MORSE-projektia Tornion terästehtaalle on kehitetty prosessimalli kuvaamaan VKU2:n toimintaa. Projektin tavoitteena on optimoida raaka-aineiden ja energiankäyttöä prosessiteollisuudessa Euroopan alueella. Terästeollisuudessa tavoitteena on parantaa saantoa 10 % ja vähentää energiankulutusta 2 %. Itse malli on jaettu kahteen osaan, joista toinen on BFI:n kehittämään malliin perustuva malli, joka kuvaa teräksen kemiallista koostumusta ja lämpötilan kehitystä prosessin aikana. BFI:n malli perustuu Köhlen malliin, jota on käyty läpi aiemmin luvussa 4.1.2. Toinen osa on Cybernetican kehittämä



malli, joka savukaasujen ja jäähdytysvesikierron lämpötiloja seuraamalla määrittää lämpöhäviöitä valokaariuunissa. Lisäksi hukkamallit mallintavat laitteisiin sitoutuvaa energiaa. Tästä hyvänä esimerkkinä on se, kuinka malli ottaa huomioon, jos uuninvuoraus on vasta uusittu. Cybernetican malli on siis rakennettu BFI:n mallin ympärille täydentämään sitä. Kun yhdistetään tiedot sulatusprosessista mallista saataviin häviöihin, saadaan aikaan malli, jota voidaan käyttää hyväksi, kun VKU2:ta kehitetään energiatehokkaammaksi. Lisäksi malli seuraa sulatusajan optimointimallin tavoin säröä. Malliin perustuvalla uunin ohjaamisella pyritään minimoimaan ylimääräisen energian käyttöä ja yhtäaikaaisesti sulattamaan mahdollisimman suuri määrä terästä. MORSEVKU2-malli myös mahdollistaa valokaariuunin operaattoreille panoksen sulamisasteen seuraamisen reaaliajassa, ja se antaa ennustuksen sulatuksen energiantarpeesta jo ennen sulatuksen aloitusta aiempien sulatusten perusteella. Tärkeimpiä mallin ennustamia arvoja ovat energiantarve, kaatopaino ja kaatolämpötila. Lisäksi malliin perustuva simulaattori on kehitteillä. Kuvassa 23 on esitetty yhdelle sulatukselle mallin online-näkymästä mallinnettu sulan teräksen lämpötila, sulan teräksen massa, energiankulutus tuotettua terästonnia kohden ja kuonan massa. Sulatuksessa on käytetty kahden korin sulatuspraktiikkaa. Lisäksi online-näkymässä on useita muita mallinnettuja ja mitattuja parametreja, jotka on esitetty liitteessä 4. (Wasbo & Jawahery 2019)




Kuva 23. Mallinnettu sulan teräksen lämpötila, sulan teräksen massa, energiankulutus tuotettua terästonnia kohden ja kuonan massa.

Jo kuten aiemmin mainittiin, luvussa 4.1.2 on käyty läpi Köhlen mallia, johon BFI:n malli perustuu. Luvussa 4.1.5 Köhlen mallia on lähdetty kehittämään neuroverkkojen avulla, ja mallin tarkkuutta on onnistuttu kehittämään. Luvussa 4.1.9 on käyty läpi simulaattoria, joka perustuu matemaattiseen malliin. Simulaattorin malli on hyvin erilainen verrattuna Cybernetican kehittämään simulaattoriin, ja näiden kahden eroavaisuuksien tutkiminen voisi auttaa arvioimaan, millaisia simulaattoreja jatkossa teollisuuden käyttöön tulisi kehittää.

## **5.7 Elektrodien kulumismalli**

Elektrodien kulumismallilla seurataan VKU2:n elektrodien kulumista sulatusten välissä tapahtuvien mittausten avulla. Kun elektrodit on nostettu yläasentoon, järjestelmä mittaa paineen hydraulikkajärjestelmästä, joka vastaa elektrodiaarmien liikuttamisesta. Ennen kuin järjestelmä mittaa paineen, tulee täyttyä tiettyjä ehtoja, esimerkiksi uunin tulee olla vaakatasossa ja elektrodiaarmien sijainti yläasennossa riittävän pitkään. Tällöin systeemi mittaa hydraulijärjestelmän paineen keskiarvona määrätyllä aikavälillä ja käyttöliittymälle siirtyy tieto elektrodin painosta. Systeemi mittaa painon jokaiselle elektrodille erikseen. Näiden mittapisteiden avulla elektrodien kulumismalli piirtää käyttöliittymään ennusteen elektrodien kulumisesta jatkossa. Kuvassa 24 on esitetty elektrodien kulumismallin operaattorinäkömän versio 0.8. Näkymästä pystyy seuraamaan jokaisen elektrodin kulumista yksilöllisesti, ja näkymässä on arvio sitä, kuinka monta sulatusta elektrodit vielä kestävät. Lisäksi näkymästä on mahdollista seurata myös, miten elektrodien toimittaja vaikuttaa niiden kulumiseen. Mallin tavoitteena on siis mahdollistaa eri elektroditoimittajien vertailu pitkällä aikavälillä ja lyhyellä aikavälillä mahdollistaa tarkastelu siihen, kuinka uunin ajopraktiikan muutokset vaikuttavat elektrodien kulutukseen.



Kuva 24. Elektrodien kulumismallin operaattorinäköymä.


Luvussa 4.1.10 on käyty läpi laskennallista mallia elektrodien kulumisen seuraamiseen. Malli eroaa merkittävästi Outokummulla käytössä olevasta mallista, ja sen ongelmaksi tuotannossa on vaikeus määrittää hapettuvan elektrodin pinta-ala. Mallin hyvänä puolena on kuitenkin mahdollisuus seurata sublimoitumisesta ja hapettumisesta tapahtuvaa kulumista erikseen. Lisäksi yhtälöistä (26) ja (27) sekä taulukosta 13 saadaan selville tekijöitä, jotka vaikuttavat elektrodien kulumiseen ja tätä tietoa voidaan käyttää hyväksi Outokummun elektrodien kulumismallin validoinnissa. Joitain näistä tekijöistä on esitetty myös elektrodien kulumisen operaattorien näkymässä Top-6-parametrit kohdassa.

## 5.8 ValuA

ValuA on tuotannonajoitusmalli, joka seuraa raaka-ainepihaa ja sulaton 1- ja 2-linjoja. Käyttöliittymässä linjat on jaettu erilleen ja eri prosessivaiheiden etenemistä on mahdollista tarkkailla. Lisäksi käyttöliittymästä näkee senkkojen sijainnin ja prosessipaikkojen häiriökoodit. Malli seuraa ennalta-asetettujen parametrien avulla prosessien etenemistä. Näiden parametrien avulla se ennustaa jokaisen sulatuksen avulla sulatuksen keston valokaariuunille. Prosessihäiriöiden tapahtuessa malli huomioi häiriöt ennusteeseen ja korjaa ennustetta näiden perusteella. Tiedot prosesseista ja niiden etenemisestä ValuA saa Qmadosta. Kuvassa 25 on esitetty ValuA:n näkymä linja 2:lle. Punaiset viivat näkymässä viittaavat häiriöön tai odotukseen. Sulatusten kestot valokaariuunille on määritetty kiinteiden parametrien avulla. Parametrejä valokaariuunille ovat tavoite-energia, ajetun ja jäljellä olevan energian suhdeluku, romukorin siirtoaika, käsittelyaika eri teräslajeille, romukorien panostuksen lisäämisaika,



DynArCOS saa 2-tason automaatiojärjestelmästä, mutta sitä on mahdollista operoida myös manuaalisesti. Kuvassa 26 on esitetty DynArCOS:in säätöperiaate VKU2:lla. PLC on säätöpiirin ohjelmoitava logiikka, joka ohjaa prosessia syötetyn ohjelman perusteella. VKU2:lla tämä ohjelmoitava logiikka on esimääritetyt jänniteportaat. (Vatron 2009)



Kuva 26. DynArCOSin toimintaperiaate VKU2:n säädössä (mukaillen Vatron 2009).

### 5.9.1 Elektrodien säätösystemi ArCOS

DynArCOS:in rinnalla VKU2:lla käytetään ArCOS-elektrodinsäätöä. DynArCOS on päivitys ArCOS-säätösystemiin, jonka avulla säätöjärjestelmän dynaamisuus kasvaa. Panoksen ja elektrodin väliin syntyvään valokaareen voidaan vaikuttaa säätämällä jännitettä, virtaa tai impedanssia. Impedanssisäätö perustuu elektrodien kautta kulkevan virran ja jännitteen mittaamiseen. Säätöjärjestelmä laskee reaaliaikaisesti virran ja jännitteen välistä vaiheensiirtoa. Käytettävän käämikytkinportaan virran ja jännitteen arvoista saadaan selville impedanssin asetusarvo. Valokaaren säätölogiikka perustuu ympyrädiagrammiin. Hydraulikkajärjestelmä säätää automaattisesti elektrodien etäisyyttä panoksesta vastaamaan impedanssin asetusarvoa, jos asetusarvo ja mitatut arvot poikkeavat toisistaan. Järjestelmä pystyy säätämään jokaista elektrodia yksilöllisesti. Jos uunissa huomataan epätasaista kulumista tai panoksen sulamista epähomogeenisesti, voidaan impedanssin asetusarvoa muuttaa manuaalisesti. (Karassaari 2008, Vatron 2009).

### 5.9.2 ArCOS ja muita laajasti käytössä olevia valokaaren säätösystemejä

Nikolaevin et al. (2016) julkaisussa on käyty läpi erilaisia valokaaren säätösystemejä. ArCOS:in hyviksi ominaisuuksiksi on mainittu sen kyky korjata erosuuretta vaihtelevalla nopeudella sekä mahdollisuus säätää resistanssia ja valokaaren jännitettä sulatuksen lopussa, jolloin saavutetaan tasainen valokaaren pituus. Huonoja puolia ArCOS:issa on sähköisen ja hydraulisen piirin yhdistäminen yhdeksi epälineaariseksi kokonaisuudeksi sekä lisäksi suuri määrä parametreja erilaisille muuntaja- ja kelakombinaatioille käyttöönoton aikana tai tehtäessä muutoksia. Julkaisussa on käyty läpi myös HIREG-, EMPERE- ja DECTEQ-elektrodien säätösystemejä ja niiden huonot, ja hyvät puolet on esitetty kuvassa 27. (Nikolaev et al. 2016)

ARCOS (Siemens VAL Primetals Technologies)		EMPERE (Aimac Spic, France)	
Advantages	Disadvantages	Advantages	Disadvantages
1. Regulator structure defines different levels of operating speed for different meanings of regulating error 2. The possibility of resistance and electric arc voltage regulating at late stages of heat to keep constant meaning of arc length	1. Combination of characteristics of electric and hydraulic circuit in one non-linear block 2. A great number of unique characteristics for each combination of furnace transformer and reactor taps in common with closed algorithms of definition non-linear block parameters	1. Wide range of regulating parameters (phase impedance $Z_{ph}$ , electric arc resistance $R_{ARC}$ , electric arc voltage $U_{ARC}$ ) 2. Use of intellectual forming set point system, based on regulator, operating on the principles of fuzzy logic	1. Closed linearization algorithms of servo valve characteristic 2. The possibility of operating speed adjustment in different regulation ranges is missing 3. Fuzzy regulator structure is closed for study and consequently it's difficult enough to evaluate its efficiency
HIREG (Danesh, Italy)		DECTEQ (Ferrotron, Germany)	
Advantages	Disadvantages	Advantages	Disadvantages
1. Division of the control blocks for electric and hydraulic circuits 2. The possibility of manual adjustment of system operating speed for variable regulating error ranges	1. Limited set of instruments for non-linear characteristic correction 2. Approach used in the system for linearization does not provide servo valve dead zone compensation and its gain properties in range of significant shifts	1. System structure is open, so it's easy to adjust 2. it's possible to linearize servo valve dead zone	1. The possibility of direct electric arc current regulating causes doubts relatively to three phase EAF due to poor dynamic regulating indications 2. No possibility of definition of operating speeds for different regulating error ranges 3. No possibility of servo valve gain properties linearization in significant shifting ranges

Kuva 27. Yleisimpien valokaaren säätösystemien hyvät ja huonot puolet (mukailten Nikolaev et al. 2016).

## 5.10 Yhteenveto Torniossa käytettävistä malleista

VKU2:lla on käytössä useita samankaltaisia malleja kuin luvussa 4 esitetyt. Mallien toimintaperiaatteet kuitenkin joissain tapauksissa eroavat merkittävästi, vaikka mallinnuksen kohde on sama. Suurimpana puutteena tällä hetkellä prosessin ohjaamisen kannalta on energiamallin käytön puute. Hyvän energiamallin käytöllä pystyttäisiin vähentämään vaihtelua kaatopainoissa ja kaatolämpötiloissa.

Tornion valokaariuuneja voitaisiin vertailla kuten luvussa 4.1.6 on vertailtu Bochumin 75 tonnin uunia ja Krefeldin 145 tonnin uunia. Jos uunien toiminta havaittaisiin riittävän samankaltaiseksi, voitaisiin uusia malleja ja mittausmenetelmiä kokeilla toisella uunilla,

minkä jälkeen voitaisiin tehdä päätös, onko näiden kehittämistä kannattavaa jatkaa myös toiseen uunin.

Kaiken kaikkiaan Torniossa on käytössä laaja kokoelma hyviä malleja, ja parhaisiin tuloksiin päästään kehittämällä tämänhetkisiä malleja. Laajan mallikokoelman ongelmaksi nousee kuitenkin niiden luonti erikseen ja niiden yhtenäistäminen toimivaksi kokonaisuudeksi. Lisäksi tiedonkeruumenetelmien kehityksen avulla pystyttäisiin kehittämään mallien tarkkuutta ja toimintaa sekä mahdollistamaan uusien mallinnusmenetelmien käyttö. Taulukossa 15 on esitetty VKU2-mallien tehtävät ja taulukossa 16 on esitetty mallien käyttäjät.

Taulukko 15. VKU2-mallit ja niiden tehtävät.

Malli	Ohjaus- malli	Offline- malli	Energian- tarve	Sulan koostumus	Kaato- paino	Kaato- lämpötila
Paukku/SulO		x		x	x	
Esilaskenta	x			x	x	
Prosessi- mallit		x	x	x		x
Sulatusajan optimointi- malli		x	x		x	x
MORSE- VKU2		x	x		x	x
Elektrodien kulumismalli		x				
ValuA	x					
DynArCOS	x					

Taulukko 16. VKU2-mallit ja niiden käyttäjät

Malli	Operaattorit	Työnjohto	Raaka-ainepiha	Kehitys
Paukku/SulO	x	x	x	x
Esilaskenta	x			
Prosessi-mallit				
Sulatusajan optimointi-malli	x			x
MORSE-VKU2	x			x
Elektrodien kulumismalli	x			x
ValuA	x	x	x	x
DynArCOS	x			



## 6 VKU2-MALLIEN VALIDOINTI

Tässä luvussa arvioidaan VKU2:lla käytettävien mallien kykyä mallintaa kaatopainoa, kaatolämpötilaa, energiantarvetta ja teräksen koostumusta sekä muita parametrejä. Tarkoituksena oli validoida myös kuonamalleja, mutta niistä ei saatu dataa diplomityön aikana. Tavoitteena on pyrkiä tutkimaan, kuinka hyvin mallit suoriutuvat ja löytyykö niistä systemaattisia virheitä. Lisäksi pyritään mallintamaan prosessin energiantarvetta luvussa 4.1.2 läpikäydyn Köhlen mallin avulla. Datasta on huomioitavaa, että sulatusnumerot linja 2:lla ovat aina parillisia lukuja ja että validoinnissa käytettävä data vaihtelee mallien välillä. Kuvien 28-83 otsikoiden perässä on sulkujen sisällä mallin nimi, johon kuva liittyy.

Sulatusajan optimointimallin validointi on jaettu versioihin yksi ja kaksi. Versio 1:n validointi on tehty ennen mallin käyttöönottoa ja versio 2:n mallin käyttöönoton jälkeen. Mallin käyttöönotto toteutettiin 18.3.2020. Lisäksi versiossa 2 käytetään dataa vainniistä sulatuksista, joissa operaattori on syöttänyt sähköenergiaa lähes saman määrän kuin malli oli ehdottanut käytettäväksi. Tällöin voidaan olettaa, että malli kokonaisuudessaan suoriutuisi paremmin kuin versiossa 1, koska kaatopaino- ja kaatolämpötilamalli laskevat tulokset mallinnetulle energialle.

Myös MORSEVKU2-mallille validointi jaettiin samaan tapaan versioihin 1 ja 2 kuten Sulatusajan optimointimallin validoinnissa. Erona on kuitenkin se, että MORSEVKU2-malli mallintaa energiantarpeen, kaatolämpötilan ja kaatopainon erikseen eli voidaan olettaa, että samanlaista parannusta mallin tarkkuudessa ei tapahdu kuin sulatusajan optimointimallissa.

Panoslaskennan ja esilaskennan validointi on jaettu myös kahteen eri osaan, vaikka niiden laskentamalli Paukku on täysin sama. Tässä luvussa Paukun validoinnilla tarkoitetaan Paukun laskeman reseptin validointia ja esilaskennalla Paukun validointia siinä tilanteessa, kun tiedetään jo toteutunut romukoreihin lastattu panos. Paukku validointivaiheessa siis validoidaan, kuinka hyvin resepti on pystytty toteuttamaan toteutuneessa sulassa. Esilaskentavaiheessa tiedetään toteutunut panos, ja sen perusteella Paukku mallintaa lopullisen kaatopainon ja teräksen koostumuksen.


Selitysaste  $R^2=1$  tarkoittaa, että malli pystyy kuvaamaan todellisuutta täydellisesti ja  $R^2=0$  vastaavasti tarkoittaa, että malli ei pysty kuvaamaan todellisuutta millään tasolla. Selitysaste ei kuitenkaan ota huomioon, onko mallissa systemaattista virhettä, joka on vakio. Esimerkiksi, jos malli systemaattisesti mallintaa tuloksen 10 yksikköä liian korkeaksi, tämä virhe ei näy tarkasteltaessa selitystasetta. Korrelaatiokertoimet  $r=1$  ja  $-1$  ja tarkoittavat täydellistä korrelaatiota ja  $r=0$  tarkoittaa, ettei korrelaatiota ole.

## 6.1 Kaatopaino


Kaatopainomalleja validoitaessa mallinnustulosta verrataan kaadon jälkeen mitattuun kaatopainoon. Mitattua kaatopainoa voidaan pitää luotettavana tuloksena vertailun kannalta. Kuitenkin joissain tapauksissa senkkaan jätetään osa sulasta, jotta panoskoko AOD:lla ei kasvaisi liian suureksi. Lisäksi on mahdollista, että osa panostetusta materiaalista ei tule ulos ja jää uuniin. On siis mahdollista, että näistä syistä validoinnissa syntyy joitain virheitä.

### 6.1.1 MORSEVKU2 versio 1


MORSEVKU2-mallia validoitaessa käytettiin dataa sulatuksista 17354-18100. Datasta suodatettiin pois kaikki rivit, joissa malli oli ennustanut kaatopainoksi alle 120 tonnia tai yli 160 tonnia. Tarkasteltavaa dataa jäi jäljelle 206 sulatuksen verran ja suodatettuja sulatuksia oli 69. Kuvassa 28 on mallinnetun ja mitatun kaatopainon regressioanalyysi. Mallin selitystasteeksi saadaan  $R^2 = 0,006$  eli malli ei pysty mallintamaan kaatopainoa lähes ollenkaan. Kuvan 29 histogrammista ja kuvan 30 aikasarjakuvaajasta voidaan todeta, että malli systemaattisesti arvioi kaatopainon liian korkeaksi. Mallin ongelmiksi nousevat sen matala selitysaste, sen systemaattinen kaatopainon liian korkeaksi mallinnus ja suuri määrä mallinnuksia, jotka ovat niin sanotusti mahdottomia. 206 sulatuksen datasta 30 % sulatuksista oli mallinnettu alueen 120-160 tonnia ulkopuolelle. Vertailukohtana tällä on, että kaikki mitatut kaatopainot olivat alueella 120-157 tonnia.



Kuva 28. Regressioanalyysi: Mallinnettu kaatopaino ja mitattu kaatopaino (MORSEVKU2 v1).




Kuva 29. Histogrammi: Mallinnettu kaatopaino ja mitattu kaatopaino (MORSEVKU2 v1).



Kuva 30. Aikasarjakuvaaja: Mallinnettu kaatopaino ja mitattu kaatopaino (MORSEVKU2 v1).


Kuvassa 31 on esitetty valvontakortti kaatopainomallille, jossa yläraja on 3 tonnia ja alaraja -3 tonnia. Samassa kuvassa on esitetty, kuinka suuri osa mallinnoista oli väärässä alle 3 tonnia, 3-6 tonnia ja yli 6 tonnia. Mallinnus on hyvä, jos sen virhe on alle 3 tonnia. Mallinnuksen tulos on tyydyttävä, jos virhe on välillä 3-6 tonnia, ja virheen ollessa yli 6 tonnia mallinnuksen tulosta voidaan pitää huonona. Tämän valvontakortin perustella malli siis suoriutuu erittäin huonosti.




Kuva 31. Valvontakortti: Mallinnettu kaatopaino ja mitattu kaatopaino (MORSEVKU2 v1).

### 6.1.2 MORSEVKU2 versio 2

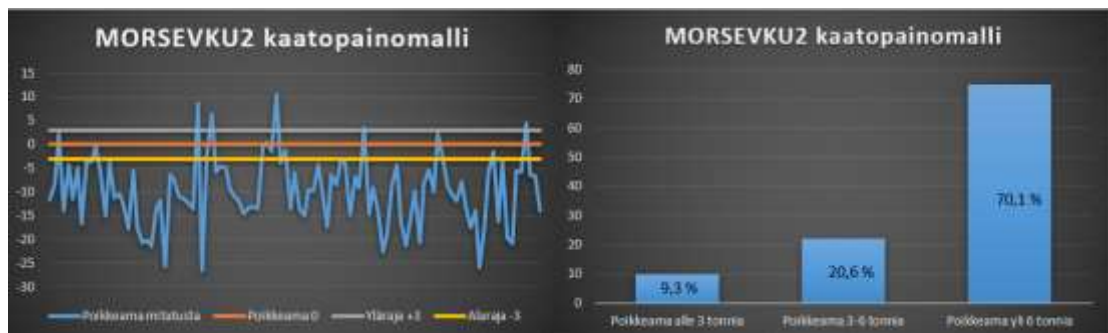
Luvussa 6.3.2 on esitelty, kuinka data on suodatettu tätä validointia varten. Käytettäessä suodatettua dataa kaatopainomalli saa selitysasteeksi  $R^2 = 0,038$ , joka on hyvin matala, mutta hieman parempi kuin datalle, jossa suodatusta ei käytetty. Tämä ero on kuitenkin hyvin merkityksetön. Regressioanalyysi on esitetty kuvassa 32. Kuvassa 33 esitetystä histogrammista nähdään, että suodatetulle datalle esiintyy sama keskiarvovirhe, joka ilmeni käytettäessä suodattamatonta dataa. Kuvassa 34 on esitetty valvontakortti, jossa on käytetty samoja valvontarajoja kuin luvun 6.1.1 valvontakortissa. Valvontakortista nähdään, että suodatetulla datalla malli ei myöskään valvontakortin perusteella suoriudu merkittävästi paremmin kuin suodattamattomalla datalla.



Kuva 32. Regressioanalyysi: Mallinnettu kaatopaino ja mitattu kaatopaino (MORSEVKU2 v2).



Kuva 33. Histogrammi: Mallinnettu kaatopaino ja mitattu kaatopaino (MORSEVKU2 v2).




Kuva 34. Valvontakortti: Mallinnettu kaatopaino ja mitattu kaatopaino (MORSEVKU2 v2).


### 6.1.3 Sulatusajan optimointimalli versio 1

Sulatusajan optimointimallin kaatopainomallia validoitaessa käytettiin dataa sulatuksista 18188-18312, joista dataa on yhteensä 62 sulatuksesta. Kuvassa 35 esitetyssä regressioanalyysissä mallin selityssasteeksi on saatu  $R^2 = 0,006$ , joka on hyvin matala. Kuvan 36 histogrammin ja kuvan 37 aikasarjakuvaajan perusteella sulatusajan optimointimalli ennustaa kaatopainon systemaattisesti korkeammaksi kuin se


todellisuudessa on. Todennäköisesti tämä johtuu siitä, että malli ei ota huomioon sitä, että osa teräksestä päätyy kuonaan ja poistuu savukaasujen mukana uunista. Tämän datajoukon perusteella mallin hyvänä puolena on se, että se ei tuota mallinnuksia, jotka ovat selvästi väärässä ja kaikki mallinnukset ovat järkevällä alueella.



Kuva 35. Regressioanalyysi: Mallinnettu kaatopaino ja mitattu kaatopaino (Sulatusajan optimointimalli v1).

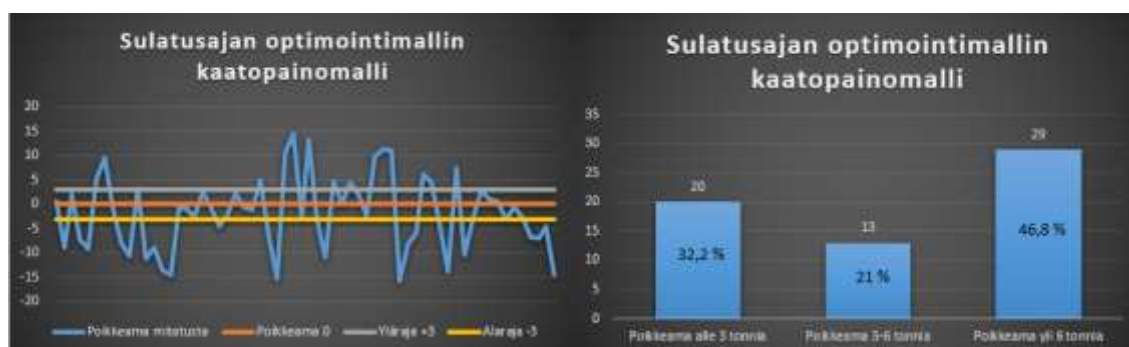


Kuva 36. Histogrammi: Mallinnettu kaatopaino ja mitattu kaatopaino (Sulatusajan optimointimalli v1).



Kuva 37. Aikasarjakuvaaja: Mallinnettu kaatopaino ja mitattu kaatopaino (Sulatusajan optimointimalli v1).


Kuvassa 38 esitetyssä valvontakortissa on käytetty samoja valvontarajoja kuin luvussa 6.1.1 läpikäydyssä valvontakortissa. Sulatusajan optimointimallin kaatopainomalli suoriutuu huomattavasti paremmin kuin MORSEVKU2-mallin kaatopainomalli suoriutuu sen validoinnin versiossa 1. 53,2 % sulatusajan optimointimallin kaatopainomallin mallinnuksen virheistä on alle 6 tonnia, kun vastaavasti MORSEVKU2-mallin kaatopainomallin virheistä vain 24,3 % on alle 6 tonnia. Tämän perusteella malli siis suoriutuu kohtuullisesti verrattuna vertailukohtana olevaan malliin.




Kuva 38. Valvontakortti: Mallinnettu kaatopaino ja mitattu kaatopaino (Sulatusajan optimointimalli v1).

#### 6.1.4 Sulatusajan optimointimalli versio 2


Luvussa 6.3.2 on käyty läpi, kuinka data on suodatettu tätä validointia varten tähän lukuun. Kuvassa 39 esitetyssä regressioanalyysissä mallin selitysasteeksi on saatu  $R^2$  0,102, joka on selkeästi korkein selitysaste kaatopainomalleille. Kuvan 40 histogrammin ja kuvan 41 aikasarjakuvaajan perusteella voidaan havaita, että malli ei systemaattisesti ennusta kaatopainoa liian korkeaksi tai matalaksi. Lisäksi aikasarjakuvaajasta nähdään, että malli ei pysty erityisen hyvin tunnistamaan tilanteita, joissa kaatopaino on erityisen korkea tai matala. Kuitenkin vastaavasti tilanteissa, joissa kaatopaino on normaali, malli toimii hyvin.



Kuva 39. Regressioanalyysi: Mallinnettu kaatopaino ja mitattu kaatopaino (Sulatusajan optimointimalli v2).



Kuva 40. Histogrammi: Mallinnettu kaatopaino ja mitattu kaatopaino (Sulatusajan optimointimalli v2).

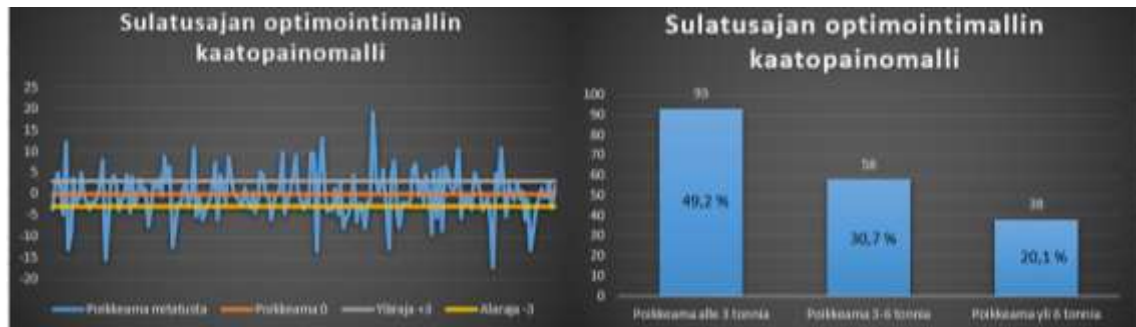


Kuva 41. Aikasarjakuvaaja: Mallinnettu kaatopaino ja mitattu kaatopaino (Sulatusajan optimointimalli v2).

Kuvassa 42 esitetyssä valvontakortissa on käytetty samoja valvontarajoja kuin luvussa 6.1.1 läpikäydyssä valvontakortissa. Nähdään, että datan suodatuksen jälkeen lähes 50 % mallinnustuloksista on täyttänyt hyvän mallinnuksen ominaisuudet ja vain 20 %




mallinnustuloksista on ollut huonoja. Tämän perusteella mallin voidaan todeta, että malli toimii erityisen hyvin teollisessa käytössä verrattuna muihin malleihin.




Kuva 42. Valvontakortti: Mallinnettu kaatopaino ja mitattu kaatopaino (Sulatusajan optimointimalli v1).

### 6.1.5 Paukku


Panosta laskettaessa Paukku määrittää sulalle teräkselle tavoitekaatopainon. Tarkastelussa on käytetty dataa sulatuksista 17226-18006. Datasta on poistettu rivit, joissa jokin osa datasta oli tyhjää, ja sulatuksia tarkasteltavaksi jäi 383 kappaletta. Kuvassa 43 esitetty regressioanalyysi antaa Paukulle selitysasteeksi  $R^2 = 0,02$ , joka on myös hyvin matala. Kuvasta 45 nähdään, että terässulan reseptien keskiarvo on 138,5 tonnia ja toteutuneen terässulan keskiarvo on 136,6 tonnia. Lisäksi kuvan 44 aikasarjakuvaajasta nähdään, että valtaosan ajasta toteutuneen sulan määrä on matalampi kuin reseptissä määritetyn sulan määrä. Tämän datan perusteella siis voidaan olettaa, että Paukku systemaattisesti laskee sulamäärän korkeammaksi kuin se todellisuudessa on. Edellä mainitut asiat voidaan myös havaita kuvassa 45 esitetyssä histogrammissa. Kuvasta 43 nähdään, että reseptien kaatopaino on tyypillisesti 137 ja 139 tonnia. Tilanteessa, jossa reseptin kaatopaino on 137 tonnia, on toteutuneiden kaatopainojen keskiarvo 135,7 tonnia, ja kun reseptin kaatopaino on ollut 139 tonnia on kaatopainojen keskiarvo 136,9 tonnia. Eli myös näissä tapauksissa malli on ennustanut kaatopainon korkeammaksi kuin se todellisuudessa on. On mahdollista, että kaatopaino määritettään systemaattisesti korkeammaksi reseptissä kuin se todellisuudessa on, koska osa teräksestä päättyy kuonapataan ja päättyy savukaasujen mukana ulos uunista.



Kuva 43. Regressioanalyysi: Sulan määrä reseptissä ja toteutuneen sulan määrä (Paukku).



Kuva 44. Aikasarjakuvaaja: Sulan määrä reseptissä ja toteutuneen sulan määrä (Paukku).




Kuva 45. Histogrammi: Sulan määrä reseptissä ja toteutuneen sulan määrä (Paukku).


### 6.1.6 Esilaskenta

Panostettujen materiaalien perusteella Paukku määrittää sulalle kaatopainon esilaskentavaiheessa. Tarkastelussa on käytetty dataa sulatuksista 18978-19206 yhteensä 113 sulatuksen verran. Esilaskenta laskee sulatuksen aikana useita kaatopainoja, mutta tässä validoinnissa datasta on käytetty ainoastaan sulatusten viimeiset mallinnukset.


Kuvassa 46 on esitetty regressioanalyysi esilaskennan mallinnuksille ja toteutuneelle kaatopainolle. Esilaskentavaiheessa Paukku saa selityssasteeksi  $R^2 = 0,014$ , joka on jälleen hyvin matala. Kuvassa 47 esitetystä aikasarjakuvaajasta nähdään, että esilaskentavaiheessa mallinnettu kaatopaino vaihtelee merkittävästi verrattuna reseptiin, jolloin mallinnetut kaatopainot olivat pääasiassa joko 137 tai 139 tonnia. Tältä osin Paukku siis reagoi esilaskentavaiheessa vaihteluun panoksessa. Kuvan 48 histogrammista voidaan todeta, että myös esilaskentavaiheessa Paukku mallintaa kaatopainon liian korkeaksi. Tämä johtuu myös todennäköisesti siitä syystä, että osa teräksestä päätyy kuonapataan sekä savukaasujen mukana ulos uunista, ja malli ei ota tätä huomioon.



Kuva 46. Regressioanalyysi: Sulan määrä esilaskennassa ja toteutuneen sulan määrä (Esilaskenta).



Kuva 47. Aikasarjakuvaaja: Sulan määrä esilaskennassa ja toteutuneen sulan määrä (Esilaskenta).




Kuva 48. Histogrammi: Sulan määrä reseptissä ja toteutuneen sulan määrä (Paukku).

## 6.2 Kaatolämpötila


Mallinnettua kaatolämpötilaa vertaillaan kaadon jälkeen mitattuun lämpötilaan. Tässä vertailutavassa ongelmaksi nousee sulan jäähtyminen sulatuksen lopetuksen ja lämmönmittauksen välillä. Voidaan kuitenkin olettaa, että tämä jäähtyminen ei ole tarkastelun kannalta merkittävää.

### 6.2.1 MORSEVKU2 versio 1


MORSEVKU2-mallia validoitiin Cyberneticalta saadun datan avulla. Validoinnissa on käytetty dataa sulatuksista 17354-18100. Datasta on poistettu rivit, joissa jokin osa datasta oli tyhjää, ja sulatuksia tarkasteltavaksi jäi 273 kappaletta. Kuvassa 49 on esitetty regressioanalyysi mallinnetulle ja mitatulle lämpötilalle. Mallin selitysasteeksi saatiin  $R^2 = 0,28$ . Kuvassa 50 esitetystä intervallikuvaajasta nähdään, että mallinnettujen kaatolämpötilojen keskiarvo on 1620 °C ja mitattujen 1614 °C. Kuuden asteen ero näissä lämpötiloissa on hyvin merkityksetön. Tältä osin malli suoriutuu hyvin, ja voidaan olettaa, ettei mallissa esiinny systemaattista virhettä. Lisäksi kaikki mallinnustulokset olivat järkevien rajojen sisällä. Kuvaajan selventämiseksi kuvassa 51 esitetty aikasarjakuvaaja on tehty sulatuksista 17354-17464, ja dataa on yhteensä 50 sulatuksesta. Ainoa havainto, joka tästä kuvaajasta voidaan tehdä, on mallin kohtalainen kyky tunnistaa erikoistilanteet, jolloin kaatolämpötila on ollut erityisen korkea tai matala.



Kuva 49. Regressioanalyysi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (MORSEVKU2 v1).



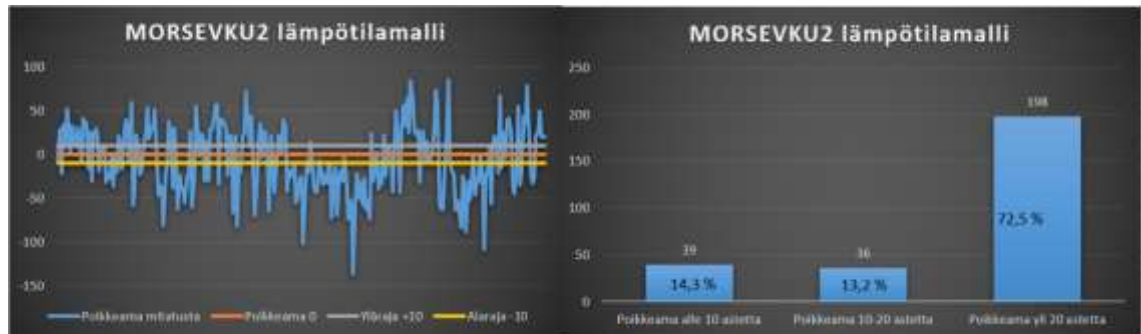
Kuva 50. Intervallikuvaaja: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (MORSEVKU2 v1).



Kuva 51. Aikasarjakuvaaja: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (MORSEVKU2 v1).

Kuvassa 52 on esitetty valvontakortti kaatolämpötilamallille. Yläraja valvontakortissa on +10 °C ja alaraja -10 °C. Samassa kuvassa on esitetty, kuinka suuri osa mallinnuksista oli väärässä alle 10°C, 10-20 °C ja yli 20 °C. Mallinnus on hyvä, jos sen virhe on alle 10 °C. Mallinnus on tyydyttävä, jos virhe on välillä 10-20 °C, ja virheen ollessa yli 20 °C mallinuksen tulosta voidaan pitää huonona. Valvontakortista nähdään, että valtaosa


mallinnuksista oli väärässä yli 20 °C. Tämän perusteella mallin suoriutuminen on hyvin heikkoa.




Kuva 52. Valvontakortti: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (MORSEVKU2 v1).

## 6.2.2 MORSEVKU2 versio 2

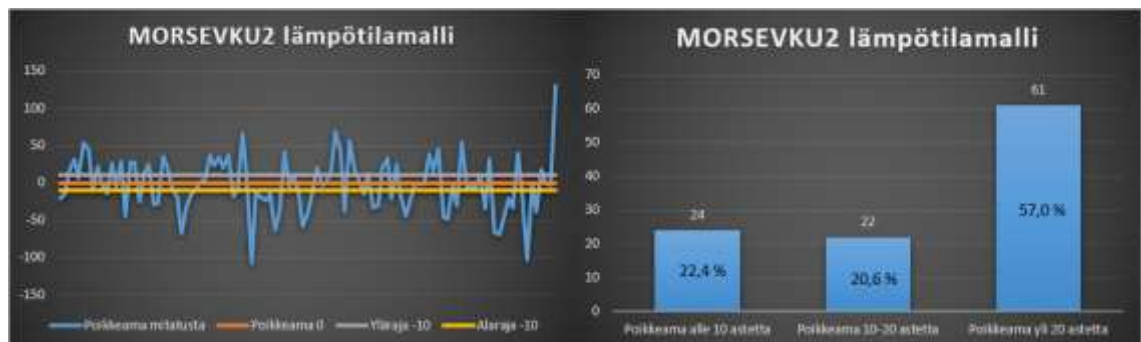
Luvussa 6.3.2 on käyty läpi, kuinka data on suodatettu tätä validointia varten tähän lukuun. Kuvassa 53 on esitetty regressioanalyysi ja kuvassa 54 on esitetty histogrammi datalle. Suodatetulla datalla malli saa selityssasteeksi  $R^2 = 0,071$ , joka on huomattavasti matalampi kuin selityssaste, joka saatiin ilman datan suodatusta. Samanaikaisesti keskiarvovirhe pieneni suodattamattoman datan 6 °C:sta vain 2 °C:een. Lisäksi kuvassa 55 on esitetty valvontakortti samoilla valvontarajoilla kuin validoinnin ensimmäisessä vaiheessa luvussa 6.2.1. Kun dataa on suodatettu, merkittävästi suurempi osa mallinnuksen virheistä on jäänyt alle 20 °C:een. Ilman suodatusta 27,5 % virheistä oli alle 20 °C ja suodatuksen jälkeen 43 %. Täten, vaikka dataa suodattaessa mallin selityssaste huononee, sen suorituskyky valvontakortin perusteella kasvaa merkittävästi.



Kuva 53. Regressioanalyysi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (MORSEVKU2 v2).



Kuva 54. Histogrammi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (MORSEVKU2 v2).




Kuva 55. Valvontakortti: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (MORSEVKU2 v2).


### 6.2.3 Sulatusajan optimointimalli versio 1

Sulatusajan optimointimallin kaatolämpötilamallia validoitaessa käytettiin dataa sulatuksista 18188-18312, joista dataa on yhteensä 62 sulatuksesta. Kuvassa 56 esitetyssä regressioanalyysissä mallin selityssasteeksi on saatu  $R^2 = 0$  eli malli ei pysty mallintamaan kaatolämpötilaa sen perusteella millään tasolla. Kuvassa 57 olevasta histogrammista nähdään, että mallinnettujen kaatolämpötilojen keskiarvo on 1612 °C ja mitattujen 1609 °C eli malli ei tämän perusteella mallinna sulan lämpötilaa systemaattisesti väärin. Histogrammista nähdään myös, että mallinnettujen tulosten vaihteluväli on merkittävästi pienempi kuin mitattujen. Kuvassa 58 esitetystä aikasarjakuvaajasta nähdään, että normaalitapauksissa malli pystyy seuraamaan mitattuja lämpötiloja ainakin jonkin verran, mutta tapauksissa, joissa sulan lämpötila poikkeaa merkittävästi normaalista, malli ei pysty havaitsemaan tätä muutosta. Mallin ongelmaksi siis nousee erityisesti kyvyttömyys mallintaa tilanteita, jotka poikkeavat normaalista. Toisaalta tämä johtaa

siihen, että kaikki mallin tulokset ovat järkevällä alueella ja tuloksia, jotka ovat mahdottomia, ei ole syntynyt. Kun dataa suodatetaan ja jäljelle jätetään vain sulatukset väliltä 1570-1660 °C, malli saa selitysteeksi  $R^2 = 0,012$  eli mallin kyky mallintaa kaatolämpötilaa tilanteissa, joissa kaatolämpötila on normaalilla alueella, on myös hyvin matala regressioanalyysin perusteella. Tämä regressioanalyysi on esitetty liitteessä 5.




Kuva 56. Regressioanalyysi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Sulatusajan optimointimalli v1).



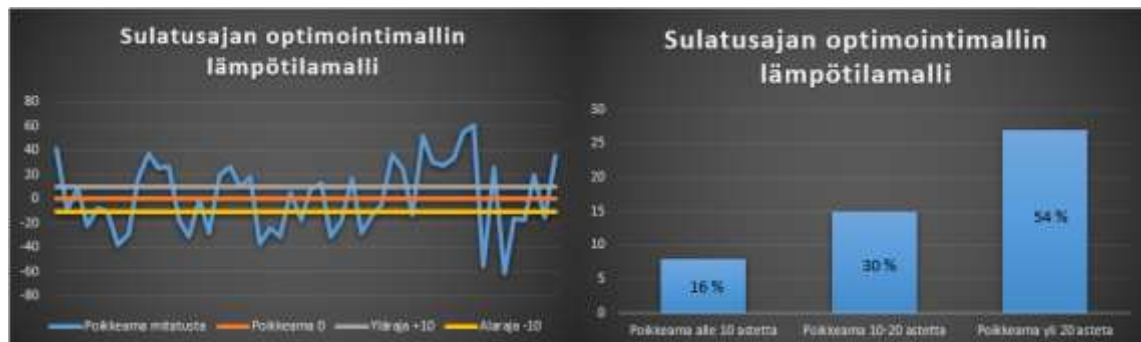
Kuva 57. Histogrammi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Sulatusajan optimointimalli v1).





Kuva 58. Aikasarjakuvaaja: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Sulatusajan optimointimalli v1).

Kuvassa 59 on valvontakortti kaatolämpötilamallille. Valvontarajoina on käytetty samoja rajoja kuin MORSEVKU2-mallin lämpötilamallin valvontakortissa. Verrattuna MORSEVKU2-mallin lämpötilamalliin tässä mallissa on huomattavasti vähemmän mallinnuksia, joissa poikkeama todellisuuteen on ollut yli 20 °C. Mutta kuitenkin myös sulatusajan optimointimallin kaatolämpötilamalli suoriutuu hyvin heikosti, koska vain 16 % mallinnuksista on valittujen valvontarajojen sisäpuolella.




Kuva 59. Valvontakortti: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Sulatusajan optimointimalli v1).


#### 6.2.4 Sulatusajan optimointimalli versio 2

Luvussa 6.3.2 on käyty läpi, kuinka data on suodatettu tätä validointia varten tähän lukuun. Kuvassa 60 on esitetty regressioanalyysi, jonka perusteella malli saa selityssasteeksi  $R^2 = 0,043$  eli sen kyky mallintaa kaatolämpötilaa suodatuksen jälkeen on edelleen hyvin heikko. Kuvan 61 histogrammin perusteella malli ei kuitenkaan


systemaattisesti mallinna kaatopainoa liian korkeaksi tai matalaksi, ja kuvassa 62 esitystä aikasarjakuvaajasta voidaan jälleen tulkita, että malli ei pysty mallintamaan tehokkaasti sulatuksia, jotka poikkeavat merkittävästi normaalista.



Kuva 60. Regressioanalyysi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Sulatusajan optimointimalli v2).

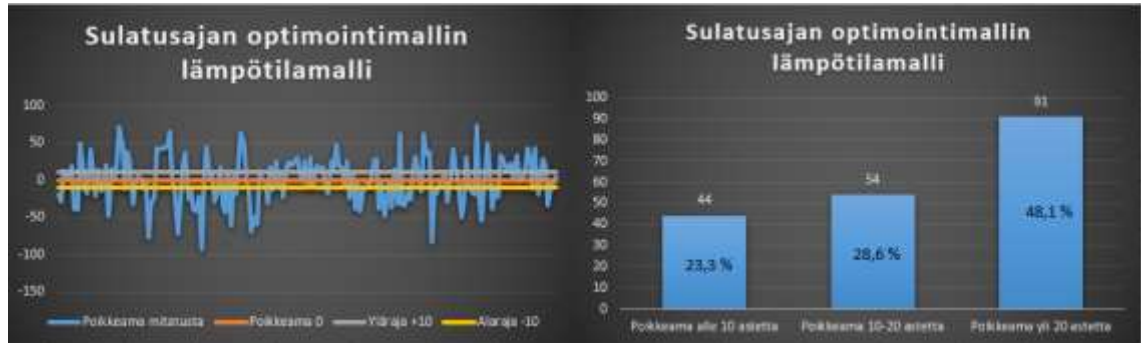


Kuva 61. Histogrammi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Sulatusajan optimointimalli v2).



Kuva 62. Aikasarjakuvaaja: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Sulatusajan optimointimalli v2).


Kuvassa 63 on valvontakortti kaatolämpötilamallille. Valvontarajoina on käytetty samoja rajoja kuin luvussa 6.2.1. Verrattuna suodattamattomaan dataan tällä datalla hieman suurempi osa mallinnuksista on ollut hyviä. Kuitenkaan tämän perusteella ei voida todeta, että datan suodattamisen jälkeen malli olisi suoriutunut merkittävästi paremmin.




Kuva 63. Valvontakortti: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Sulatusajan optimointimalli v2).

### 6.2.5 Energiamalli

Energiamalli kuuluu 2-tason malleihin, jotka on esitelty luvussa 5.4. Energiamalli mallintaa sulatuksen aikana terässulan lämpötilaa viiden minuutin välein. Samalla energiamalli, mallintaa paljonko sen mukaan sähköenergiaa tulisi vielä syöttää, jotta päästäisiin haluttuun lopputulokseen. Mallin validoinnissa käytettiin dataa sulatuksista 19000-19400 yhteensä 200 sulatuksen verran. Ensimmäisenä jokaisesta sulatuksesta validointiin valittiin viimeinen mallinnustulos ja tämän jälkeen validointiin valittiin sulatukset, joissa mallin mukaan on syötetty riittävä määrä energiaa tai liian paljon energiaa. Kuvassa 64 on esitetty regressioanalyysi mallille, jossa selitysasteeksi on saatu  $R^2 = 0,054$ . Koska tässä mallinnuksessa verrataan uunissa olevan terässulan lämpötilaa ja kaatolämpötilaa, voidaan olettaa, että mallinnustulosten tulisi olla korkeampia kuin mitattujen kaatolämpötilojen. Kuitenkin kuvassa 65 esitetystä histogrammista nähdään, että mallinnustulosten keskiarvo on merkittävästi matalampi kuin mitattujen kaatolämpötilojen. Voidaan olettaa, että mallinnustulosten keskiarvon tulisi olla noin 20 °C korkeampi kuin kaatolämpötilojen keskiarvon, koska sula jäähtyy kaadon aikana ja ennen lämmönottoa. Kuitenkin validoinnissa kaatolämpötilojen keskiarvo oli 39 °C korkeampi kuin mallinnettujen arvojen. Tämän perusteella energiamalli mallintaa lämpötilan uunissa liian matalaksi tai aliarvioi energiantarpeen prosessissa.



Kuva 64. Valvontakortti: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Energiamalli).




Kuva 65. Histogrammi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila (Energiamalli)

### 6.3 Energiantarve


Mallinnettua energiantarvetta verrataan sulatuksissa käytettyyn energiaan. Validoinnissa energialla tarkoitetaan ainoastaan sähköenergiaa. Todellisuudessa käytetty energia on sulattajan mielipide siitä, paljonko energiaa kyseiseen sulatukseen tulee käyttää. Tästä syystä energiamallien validointi, jotka mallintavat, paljonko energiaa tulisi käyttää, on hyvin vaikeaa, koska toteutunut energian käyttö ei ole todennäköisesti optimaalisin tapa toteuttaa sulatus. Eli mallin suoriutuessa hyvin se ainoastaan kuvastaa sitä, että malli pystyy mallintamaan sen, paljonko sulattaja haluaa käyttää energiaa. Todellisuudessa käytetty energia kWh/t on laskettu jakamalla käytetty energia kWh panostetuilla metallitonneilla t.

### 6.3.1 MORSEVKU2 versio 1

MORSEVKU2-mallia validoitiin Cyberneticalta saadun datan avulla. Tästä validoinnista käytettiin kaikkea dataa, joka oli järkevyyden rajoissa sulatuksista 17354-18658, joista dataa oli yhteensä 528 sulatuksesta ja vain yksi mallinnuksista oli selvästi virheellinen, jolloin tarkasteltavaa dataa jäi 527 sulatuksen verran. Malli saa tällä datalla selityssasteeksi  $R^2 = 0,984$  eli malli pystyy siis mallintamaan hyvin tarkasti, paljonko prosessin aikana käytetään energiaa. Kuvassa 66 on esitetty tämä regressioanalyysi. Kuvassa 67 on esitetty aikasarjakuvaaja 50 uusimmalle sulatukselle saadusta datasta. Kuvaajasta nähdään, että malli pystyy hyvin mallintamaan todellista energian kulutusta, mutta se systemaattisesti mallintaa energian liian matalaksi. Kun tarkastellaan kaikkea saatua dataa, mallinnetun energian keskiarvo on 408 kWh/t ja todellisen 425 kWh/t, ja tarkasteltaessa 50 sulatusta, jotka on esitetty aikasarjakuvaajassa, mallinnetun energian keskiarvo on 398 kWh/t ja todellisen 413 kWh/t. Eli malli siis mallintaa käytetyn energian systemaattisesti matalammaksi kuin se on todellisuudessa.




Kuva 66. Regressioanalyysi: Mallinnettu energia ja todellinen energia (MORSEVKU2).



Kuva 67. Aikasarjakuvaaja: Mallinnettu energia ja todellinen energia (MORSEVKU2).

### 6.3.2 MORSEVKU2 versio 2


MORSEVKU2-mallin validoinnin toisessa vaiheessa valittiin sulatukset, joissa mallinnettu energia ja todellinen energiankäyttö olivat lähes samat. Heti dataa suodattaessa ilmeni, että kun laskettiin poikkeama mitatun ja mallinnetun energian välillä, kaikki arvot olivat positiivia eli malli siis mallinsi energian aina liian korkeaksi. Sama pystyttiin havaitsemaan aiemmin kuvasta 67. Alkuperäisenä tarkoituksena poikkeaman ylärajaksi oli tarkoituksena asettaa  $\pm 10$  kWh/t, mutta datan vuoksi poikkeaman ylärajaksi asetettiin 15 kWh/t. Kuvasta 68 nähdään, että tyypillisesti mallinnuksen virhe on välillä 13-21 kWh/t. Kun datan suodatus oltiin tehty, jäi jäljelle dataa yhteensä 107, sulatuksesta kun ennen suodatusta sulatuksia oli yhteensä 528. Sama suodatus tehtiin myös MORSEVKU2-mallin kaatolämpötila- ja kaatopainodatalle.




Kuva 68. Histogrammi: Poikkeama mitattu – mallinnettu energia. (MORSEVKU2)

### 6.3.3 Sulatusajan optimointimalli versio 1

Sulatusajan optimointimallin energiamallia validoitaessa käytettiin dataa sulatuksista 18188-18312, joista dataa on yhteensä 64 sulatuksesta. Kun tästä datasta suodatettiin pois selvästi virheelliset mallinnuksen tulokset, jäi jäljelle dataa 43 sulatuksesta. Kuvassa 69 esitetyssä regressioanalyysissä malli saa selityssasteeksi  $R^2 = 0,181$ . Kuvasta 70 nähdään, että malli ei tällä datalla systemaattisesti arvioi energiantarvetta liian suureksi tai pieneksi.



Kuva 69. Regressioanalyysi: Mallinnettu energia ja todellinen energia (Sulatusajan optimointimalli v1).



Kuva 70. Aikasarjakuvaaja: Mallinnettu energia ja todellinen energia (Sulatusajan optimointimalli v1).

### 6.3.4 Sulatusajan optimointimalli versio 2

Sulatusajan optimointimallin validoinnin toisessa vaiheessa valittiin sulatukset, joissa mallinnettu energia ja todellinen energiankäyttö olivat lähes samat. Lähtödataa oli 438 sulatuksesta sulatuksista 18788-1980. Kun datasta suodatettiin pois selvästi virheelliset mallinnukset, sulatukset, joiden data oli puutteellista, ja valittiin validointiin ainoastaan sulatukset, joissa todellinen energian käyttö erosi maksimissaan 10 kWh/t mallinnetusta tuloksesta, jäljelle jäi dataa 189 sulatuksesta. Tämä sama datan suodatus tehtiin myös sulatusajan optimointimallin kaatopaino- ja kaatolämpötilamalleille.

### 6.3.5 Köhlen malli korjauskertoimella

Luvussa 4.1.3 läpikäydyn Köhlen vuoden 2001 mallin avulla mallinnettiin energiantarve 64 sulatukselle. Kaikki mallissa käytettävät arvot paitsi sulatuksen kesto ja korjauskerroin

on mahdollista määrittää ennen sulatuksen aloitusta. Hapen ja panosmateriaalien määrät saadaan Paukusta ja arvioitu kaatolämpö MORSEVKU2-kaatolämpötilamallista. Korjauskertoimen arvo 44 kWh/t saatiin määrittämällä toteutuneen ja mallinnetun energiantarpeen keskiarvot ennen korjauskertoimen käyttöä. Näiden keskiarvojen erotus oli -44 kWh/t. Korjauskerroin ei sisälly Köhlen vuoden 2001 malliin, ja se on lisätty malliin itse jälkeenpäin. Taulukossa 17 on esitetty malli ja sen parametrit. Lisäksi sulatuksen kestonä on käytetty vakioarvona 50 minuuttia.


Taulukko 17. Köhlen vuoden 2001 malli korjauskertoimella ja sen parametrit.

$$\frac{W_r}{kWh/t} = 391 + 450 * \left( \frac{G_E}{G_A} - 1 \right) + 800 * \left( \frac{G_Z}{G_A} \right) + 0,35 * \left( \frac{T_A}{^{\circ}C} - 1600 \right) + 1 * \frac{t}{min} - 2,1 * \frac{\frac{M_L}{m^3}}{t} - K$$


Parametri	Mistä arvo parametrille on saatu
Rautapitoisten materiaalien massa $G_E$	Paukku (tonnia)
Kuonanmuodostajien massa $G_Z$	Paukku (tonnia)
Kaatopaino $G_A$	Paukku (tonnia)
Kaatolämpö $T_A$	MORSEVKU2 malli ( $^{\circ}C$ )
Hapenmäärä $M_L$	Paukku ( $m^3/t$ )
Sulatuksen kesto $t$	Vakioarvo (50 min)
Korjauskerroin $K$	Vakioarvo (44 kWh/t)

Kuvassa 71 on esitetty regressioanalyysi Köhlen vuoden 2001 mallille korjauskertoimella, jossa on käytetty itse lisättyä korjauskerrointa. Selitysaste  $R^2 = 0,255$  on matala, mutta mallin yksinkertaisuuden vuoksi kohtalainen. Lisäksi mallin hyvin yksinkertaisen luonteen vuoksi sen ennuste on järkevyyden rajoissa, jos lähtötiedot ovat oikein. Kuvassa 72 esitetystä aikasarjakuvaajasta voidaan tulkita, että malli pystyy kohtalaisesti arvioimaan energiantarvetta prosessista. Lisäksi korjauskertoimen ansiosta malli ei systemaattisesti mallinna energiantarvetta liian korkeaksi tai matalaksi.





Kuva 71. Regressioanalyysi: Köhle 2001 korjauskertoimella.




Kuva 72. Aikasarjakuvaaja: Köhle 2001 korjauskertoimella.


### 6.3.6 Energiamalli

Energiamallin validoinnissa käytettiin dataa sulatuksista 19000-19400 yhteensä 200 sulatuksesta. Kuten luvussa 6.1.6 kerrottiin, energiamalli mallintaa energiantarpeen viiden minuutin välein ja validointiin on valittu ainoastaan viimeisin mallinnustulos. Mallinnettu energiantarve on laskettu lisäämällä syötettyyn energiaan mallin ehdottama jäljellä olevan energian määrä. Datasta on lisäksi suodatettu sulatukset, joissa mallin ehdottama jäljellä olevan energian määrä on ollut 0. Tätä mallinnusta on verrattu todellisuudessa syötettyyn energiamäärään. Kuvassa 73 on esitetty energiamallille regressioanalyysi, jossa saadaan selitysasteeksi  $R^2 = 0,386$ . Kuten aiemmin mainittiin luvussa 5.4.2, mallin suurimpana ongelmana on romuteräksen entalpialle määritetty vakioarvo. Kuvan 74 aikasarjakuvaajasta voidaan havainnoida, että malli systemaattisesti mallintaa energiantarpeen korkeammaksi kuin todellinen käytetty energia on. Tämä voi

myös johtaa siihen, että malli mallintaa sulan lämpötilan matalammaksi kuin se todellisuudessa on, mikä havaittiin luvussa 6.2.5.



Kuva 73. Regressioanalyysi: Mallinnettu energia ja todellinen energia (Energiamalli).



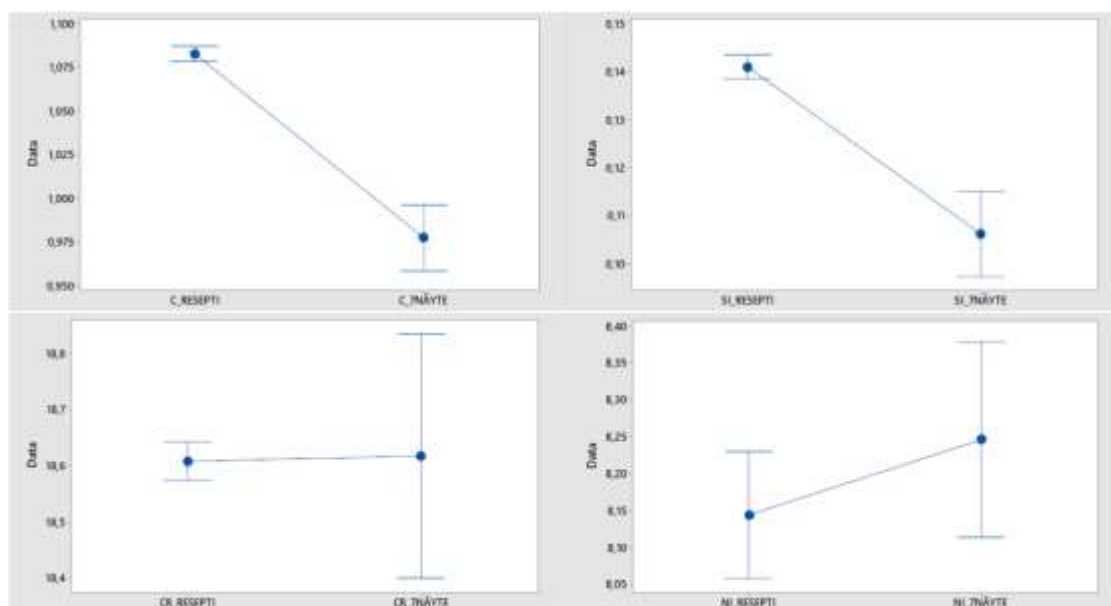
Kuva 74. Aikasarjakuvaaja: Mallinnettu energia ja todellinen energia (Energiamalli).

## 6.4 Teräksen koostumus

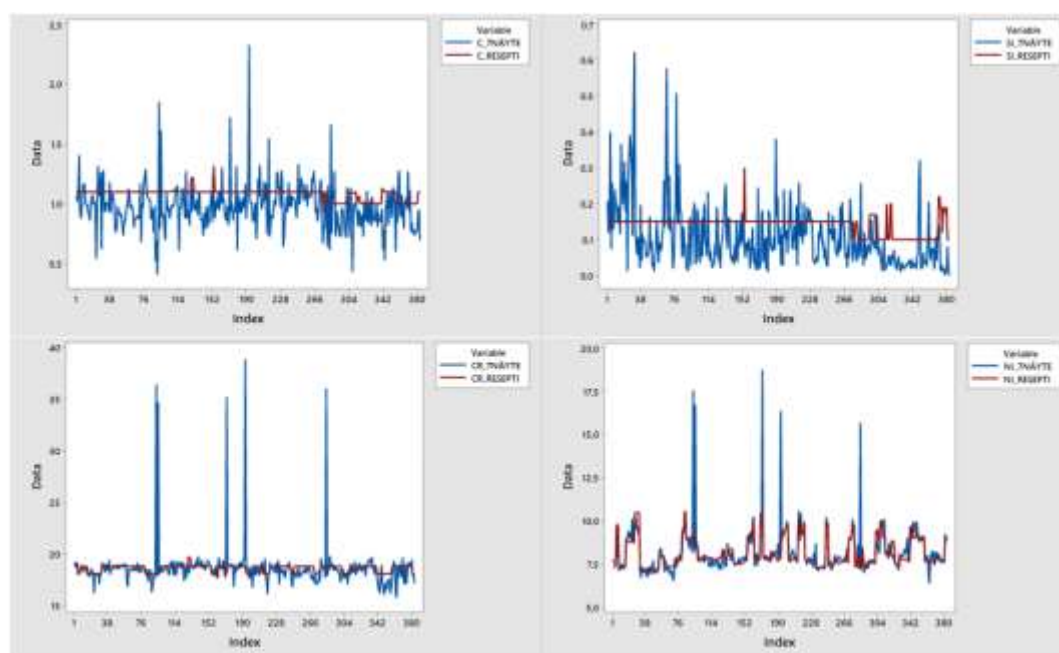
Teräksen koostumusta seuraavia malleja validoitiin vertaamalla mallinnettua tulosta 7-analyysiin, joka otetaan kaadon jälkeen. Tarkasteltaviksi komponenteiksi on valittu hiili, pii, kromi ja nikkeli, koska nämä ovat tärkeimmät komponentit ruostumattoman teräksen valmistuksessa.

#### 6.4.1 Paukku

Tässä luvussa on käytetty samaa dataa kuin luvussa 6.1.5. Kuvasta 75 nähdään, että hiilipitoisuus keskiarvollisesti reseptissä on 1,083 % ja sulassa 0,977 % ja että piipitoisuus reseptissä on 0,141 % ja sulassa 0,106 %. Lisäksi kuvasta 76 nähdään, että toteutuneet hiili- ja piipitoisuus kulkevat valtaosan ajasta reseptien määrittämien koostumusten alapuolella. Paukun määrittämän kromipitoisuuden keskiarvo on 18,61 % ja toteutuneen 18,62 %. Kuvassa 76 toteutunut määrä seuraa hyvin tarkasti reseptissä määritettyä kromimäärää, jos ei oteta huomioon muutamaa hyvin korkeaa kromipitoisuutta toteutuneessa sulassa. Käytetyssä datassa keskiarvo nikkelipitoisuudelle reseptissä on 8,14 % ja toteutunut pitoisuus on 8,25 %. Kuvassa 76 toteutunut nikkelimäärä seuraa hyvin tarkasti Paukun reseptiä muutamaa korkeaa pitoisuutta lukuun ottamatta. Paukun resepti siis toteutuu parhaiten kromin ja nikkelin osalta, eikä systemaattista virhettä ei ole havaittavissa. Hiilen ja piin osalta vaikuttaa siltä, että Paukku määrittää pitoisuudet systemaattisesti korkeammaksi kuin ne ovat toteutuneessa sulassa. Lisäksi aikasarjakuvaajista voidaan havaita, että kun hiili- ja piipitoisuudet laskevat reseptissä, niiden toteutuneet pitoisuudet ovat laskeneet huomattavasti enemmän. Liitteessä 6 on esitetty regressioanalyysi Paukulle. Mallin selitysaste hiilelle on  $R^2 = 0,028$ , piille  $R^2 = 0,036$ , kromille  $R^2 = 0,007$  ja nikkelille  $R^2 = 0,40$ . Keskiarvo selitysasteille on siis  $R^2 = 0,118$ . Kromin ja nikkelin osalta tulee ottaa huomioon, että selitysasteet olisivat olleet huomattavasti korkeammat, jos datasta olisi suodatettu pois hyvin korkeat nikkelin ja kromipitoisuudet, jotka ovat todennäköisemmin mittausvirheitä. Tällöin selitysaste kromille on  $R^2 = 0,221$  ja nikkelille  $R^2 = 0,792$ . Nämä regressioanalyysit on esitetty liitteessä 7.



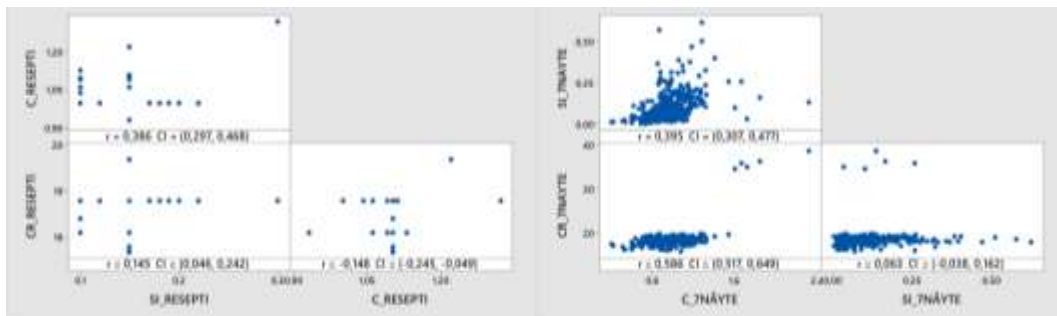
Kuva 75. Intervallikuvaaja: Hiili-, pii-, kromi- ja nikkelipitoisuudet reseptissä ja sulassa (Paukku).



Kuva 76. Aikasarjakuvaaja: Hiilen, piin, kromin ja nikkelin koostumus reseptissä ja sulassa (Paukku).

Hiilellä ja piillä on suuri vaikutus toistensa sekä kromin hapettumiseen valokaariuuniprosessissa. Kuvassa 77 on esitetty korrelaatiokertoimet hiilelle, piille ja kromille reseptissä ja sulassa. Hiilelle ja piille saadaan lähes samat korrelaatiokertoimet: reseptissä  $r = 0,386$  ja sulassa  $r = 0,395$ . Sen sijaan piille ja kromille saadaan suuresti poikkeavat korrelaatiokertoimet reseptissä:  $r = 0,145$  ja sulassa  $r = 0,586$ . Tämän perusteella Paukku ei siis pysty mallintamaan tehokkaasti, kuinka piipitoisuuden muutokset vaikuttavat kromipitoisuuteen sulassa. Aikavälillä, jolta data on otettu, on ollut


ongelmia sulan kuohumisen kanssa kaadon aikana, ja tämän seurauksena on mahdollista, että kuohumisen vähentämiseksi hiilipitoisuutta on laskettu tarkoituksella.



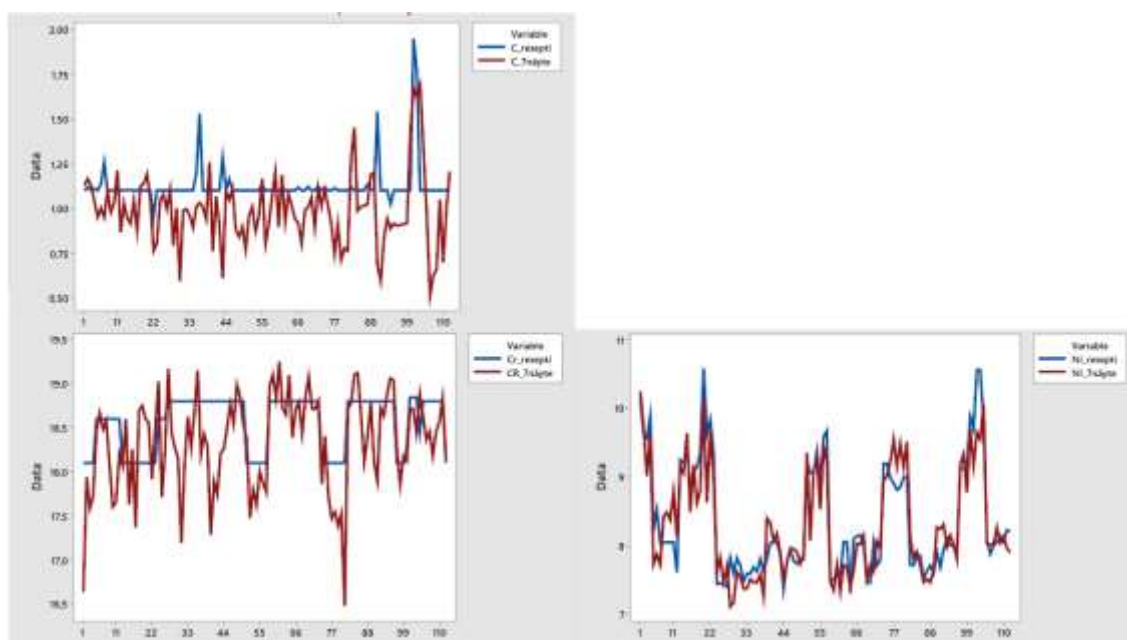
Kuva 77. Korrelaatiokerroin: Hiilen, piin ja kromin koostumus reseptissä ja sulassa. (Paukku)

#### 6.4.2 Esilaskenta

Tässä luvussa on käytetty samaa dataa kuin luvussa 6.1.5. Esilaskennan osalta piipitoisuuden kattavaa validointia ei pystytty tekemään, koska esilaskennassa tässä datassa Paukku määrittä piipitoisuudeksi aina 0,15 %. 7-näytteiden piikoostumuksen keskiarvo tällä datalla oli 0,126 % eli asetettu piikoostumus 0,15 % on keskiarvallisesti liian korkea verrattuna tähän dataan. Kuvasta 78 voidaan tulkita, että esilaskentavaiheessa Paukku määrittää hiili- ja kromipitoisuudet systemaattisesti liian korkeiksi, mutta nikkelpitoisuuden laskenta määrittää keskiarvallisesti oikein. Myös kuvassa 79 esitetystä aikasarjakuvaajasta voidaan tulkita, että malli määrittää hiilipitoisuuden systemaattisesti liian matalaksi. Kromipitoisuuden aikasarjakuvaajasta nähdään, että malli määrittää kromipitoisuuden systemaattisesti liian korkeaksi. Lisäksi nähdään, että korkeammilla toteutuneilla kromipitoisuuksilla malli määrittää kromipitoisuuden usein liian korkeaksi. Esilaskenta suoriutuu nikkeli-koostumuksen määrittelyssä myös aikasarjakuvaajan perusteella hyvin eli se pystyy seuraamaan luotettavasti nikkelpitoisuuden vaihteluja toteutuneissa koostumuksissa. Liitteessä 8 on esitetty regressioanalyysi Paukulle esilaskentavaiheessa. Mallin selitysaste hiilelle on  $R^2 = 0,109$ , kromille  $R^2 = 0,301$  ja nikkelille  $R^2 = 0,824$ . Keskiarvo selitysasteille on siis  $R^2 = 0,411$ . Tämän perusteella laskenta suoriutuu kohtalaisesti hiilen ja kromin osalta sekä hyvin nikkelin osalta. Kuten aiemmin oletettiin regressioanalyysin perusteella, malli suoriutuu esilaskentavaiheessa paremmin kuin reseptin laskentavaiheessa.



Kuva 78. Intervallikuvaaja: Hiili-, kromi- ja nikkelpitoisuudet esilaskennassa ja sulassa (Esilaskenta).




Kuva 79. Aikasarjakuvaaja: Hiilen, piin, kromin ja nikkelin koostumus reseptissä ja sulassa (Esilaskenta).

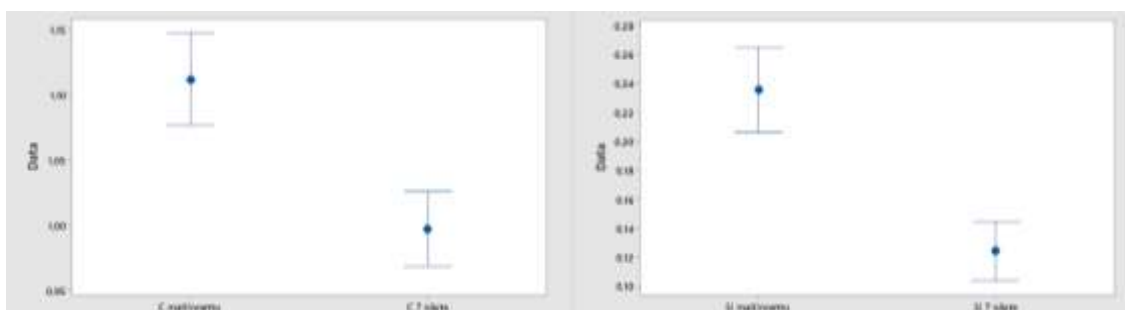
### 6.4.3 Raffinointimalli

Raffinointimalli on yksi 2-tasossa toimivista malleista, ja se mallintaa hiili- ja piipitoisuutta, ja sen validoinnissa käytettiin dataa sulatuksista 19000-19400, joista dataa oli yhteensä 200 sulatuksesta. Kuten luvussa 6.2.5 esitetty energiamalli myös raffinointimalli suorittaa mallinnuksen viiden minuutin välein, ja myös tässä validoinnissa käytettiin arvoja sulatuksen viimeisestä mallinnuksesta. Datasta ilmeni, että hyvin useasti malli mallinsi sulatuksen loppuvaiheessa piipitoisuudeksi 0, minkä

seurauksena datasta suodatettiin selkeästi virheellisinä arvoina pois 72 sulatusta. Kuvassa 80 on esitetty regressioanalyysi mallille. Hiilen mallinnukselle malli saa selitysasteeksi  $R^2 = 0,157$  ja piille  $R^2 = 0,06$ . Malli siis suoriutuu selitysasteen perusteella hyvin hiilen osalta verrattuna esilaskentaan. Piin mallinnuksen selitysaste taas viestii, että malli ei kykene mallintamaan piipitoisuutta lähes ollenkaan. Kuvassa 81 esitettyjen intervallikuvaajien perusteella malli mallintaa hiilipitoisuuden hieman liian korkeaksi ja piipitoisuuden merkittävästi korkeammaksi kuin se todellisuudessa on. Eli myös tämän perusteella malli suoriutuu hiilipitoisuuden mallinnuksesta kohtalaisesti ja piipitoisuuden mallinnuksesta hyvin huonosti.



Kuva 80. Regressioanalyysi: Hiilen ja piin koostumus mallinnuksessa ja 7-näytteessä (Raffinointimalli).




Kuva 81. Intervallikuvaaja: Hiilen ja piin koostumus mallinnuksessa ja 7-näytteessä (Raffinointimalli).

## 6.5 Elektrodien kulumismalli

Elektrodien kulumismallin validoinnissa käytettiin dataa sulatuksista 1622-18532. Datasta suodatettiin pois tyhjät rivit, ja jäljelle jäi 985 sulatusta. Validoinnissa verrattiin mallin antamaa elektrodien kulumiskerrointa käytettyyn energiaan, kaatolämpötilaan ja panospainoon. Kaikille parametreille laskettiin 10 sulatuksen keskiarvo, jota käytettiin validoinnissa. Kuvasta 82 nähdään, että käytetyllä energialla ja kaatolämpötilalla on

hyvin matala korrelaatiokerroin elektrodien kulumiskertoimeen. Sen sijaan panospainon korrelaation kulumiskertoimen ollessa  $r = -0,156$  se viestii ainakin jonkin tasoisesta korrelaatiosta. Tämähän voi olla syynä se, että kulumiskerroin määritetään per panostonni. Kuitenkaan tällä validointimenetelmä mallia ei voida todeta toimivaksi tai toimimattomaksi.



Kuva 82. Korrelaatiokerroin: Elektrodien kulumiskerroin, käytetty energia, kaatolämpötila ja panospaino. (Elektrodien kulumismalli)

## 6.6 Yhteenveto mallien validoinnista

Yleisesti validointi oli diplomityön mielenkiintoisin osa toteutuksen ja tulosten kannalta. Validoinnin aikana ilmeni suuri määrä systemaattisia virheitä mallien toiminnassa. Lisäksi pystyttiin havaitsemaan hyviä ja huonoja puolia malleista. Taulukossa 18 on esitetty selitysasteet ja datamäärä malleille, joita validoitiin, ja taulukossa 19 on esitetty mallien merkittävimmät systemaattiset virheet. Luvussa 7 validoinnin tuloksia on käyty läpi sekä pohdittu tarkemmin.



Taulukko 18. Validoinnissa läpikäytyjen mallien selitysasteet ja käytetty data.

Malli ja mallinnettava suure	Selitysaste $R^2$	Datamäärä
MORSEVKU2 v1 (kaatopaino)	0,006	206
MORSEVKU2 v2 (kaatopaino)	0,038	107
Sulatusajan optimointimalli v1 (kaatopaino)	0,006	62
Sulatusajan optimointimalli v2 (kaatopaino)	0,102	188
Paukku (kaatopaino)	0,02	383
Esilaskenta (kaatopaino)	0,014	113
MORSEVKU2 v1 (kaatolämpötila)	0,28	273
MORSEVKU2 v2 (kaatolämpötila)	0,071	107
Sulatusajan optimointimalli v1 (kaatolämpötila)	0	62
Sulatusajan optimointimalli v2 (kaatolämpötila)	0,043	188
Energimalli (kaatolämpötila)	0,054	200
MORSEVKU2 v1 (energiantarve)	0,984	528
Sulatusajan optimointimalli v1 (energiantarve)	0,181	43
Köhle 2001 (energiantarve)	0,255	64
Energiamalli (energiantarve)	0,386	200
Paukku (teräksen koostumus)	0,118	383
Esilaskenta (teräksen koostumus)	0,411	113
Raffinointimalli (teräksen koostumus)	0,0815	200
Elektodien kulumismalli (Elektodien kuluminen)	-	985

Taulukko 19. Systemaattisten virheiden esiintyminen validoiduissa malleissa.

Malli ja mallinnettava suure	Systeemaattinen virhe	Kuvaus
MORSEVKU2 v1 (kaatopaino)	Kyllä	Mallinnus systemaattisesti liian korkea
MORSEVKU2 v2 (kaatopaino)	Kyllä	Mallinnus systemaattisesti liian korkea
Sulatusajan optimointimalli v1 (kaatopaino)	Ei	Todennäköisesti ei huomioda, että kaikki teräs ei päädy senkkaan
Sulatusajan optimointimalli v2 (kaatopaino)	Ei	-
Paukku (kaatopaino)	Kyllä	Todennäköisesti ei huomioda, että kaikki teräs ei päädy senkkaan
Esilaskenta (kaatopaino)	Kyllä	Todennäköisesti ei huomioda, että kaikki teräs ei päädy senkkaan
MORSEVKU2 v1 (kaatolämpötila)	Ei	-
MORSEVKU2 v2 (kaatolämpötila)	Ei	-
Sulatusajan optimointimalli v1 (kaatolämpötila)	Kyllä	Erikoistilanteiden havaitsemisen puute
Sulatusajan optimointimalli v2 (kaatolämpötila)	Kyllä	Erikoistilanteiden havaitsemisen puute
Energiamalli (kaatolämpötila)	Kyllä	Mallinnus systemaattisesti liian matala
MORSEVKU2 v1 (energiantarve)	Kyllä	Mallinnus systemaattisesti liian matala
Sulatusajan optimointimalli v1 (energiantarve)	Ei	-
Köhle 2001 (energiantarve)	Ei	-
Energiamalli (energiantarve)	Kyllä	Mallinnus systemaattisesti liian korkea
Paukku (teräksen koostumus)	Kyllä	Hiili- ja piipitoisuuksien mallinnus systemaattisesti liian korkeaksi
Esilaskenta (teräksen koostumus)	Kyllä	Piipitoisuuden mallinnuksen puute
Raffinointimalli (teräksen koostumus)	Kyllä	Mallinnukset, joissa piipitoisuus 0%

## 7 VALIDOINNIN TULOSTEN TARKASTELU JA JOHTOPÄÄTÖKSET

Tässä luvussa käydään läpi edellisen luvun validoinnin tuloksia. Aluksi käydään läpi, millaisia ongelmia validointia suoritettaessa ilmeni ja sen jälkeen, millaisia tuloksia validoinnissa havaittiin. Carlssonin et al. (2019b) julkaisussa mainittiin, että heidän mielestään prosessimallien validoinnissa tulisi käyttää dataa ainoastaan sulatuksista, jotka olivat normaaleja ja hyvin samankaltaisia. Mielestäni kuitenkin prosessimallien tulisi toimia teollisuudessa kaikissa olosuhteissa, ja validointia suorittaessa käytin kaikkea dataa sulatuksista, jotka olivat järkevyyden rajoissa enkä esimerkiksi suodattanut pois sulatuksia, jotka olivat epätavallisen pitkiä tai muuten tavallisesta poikkeavia. Tästä syystä esimerkiksi luvussa 6 esitettyjä selityksasteita on hyvin vaikea verrata selityksasteisiin, joita oli esitetty luvussa 4, koska ei tiedetä, kuinka paljon datan suodatusta ja jopa valintaa on käytetty luvun 4 validointeja suorittaessa. Lisäksi, koska osa malleista oli kilpailevia, pyrin pitämään validoinnin mahdollisimman tasapuoleisena.

### 7.1 Ongelmat validoinnissa

Validointia tehtäessä ilmeni ongelmia, joiden vuoksi validointia ei pystytty suorittamaan optimaalisesti. Joissain tapauksissa esimerkiksi jouduttiin vertailemaan uunin sisäisiä mallinnuksia arvoihin, jotka oli mitattu kaadon jälkeen.

#### 7.1.1 Mallien nykyinen tila

Validointia tehtäessä MORSEVKU2-malli, sulatusajan optimointimalli sekä elektrodien kulumismalli olivat vielä kehitysvaiheessa, minkä seurauksena validointia suorittaessa ilmeni ongelmia. Malleja esimerkiksi kehitettiin ja niiden datan tuotto saattoi keskeytyä validoinnin aikana, minkä vuoksi ne lopettivat prosessin mallintamisen. Osa validoitavista malleista oli niin sanotusti unohdettuja malleja, joita ei enää ainakaan tietävästi käytetty mihinkään. Tämä tuotti ongelmia yleisessä tiedonkeruussa malleista ja datan saannissa.

#### 7.1.2 Ongelmat datassa

Optimaalisessa tilanteessa jokaista mallia validoitaessa olisi käytetty yhtä suurta datajoukkoa samoista sulatuksista. Kuitenkin datan hankinta osoittautui joidenkin mallien

osalta haastavaksi esimerkiksi siitä syystä, että data ei varastoitunut kovinkaan pitkäksi aikaan järjestelmiin. Lisäksi joissain sulatuksissa mallit olivat tuottaneet selkeästi virheellisiä arvoja tai eivät olleet toimineet, jolloin dataa oli pakko suodattaa.

## 7.2 Mallin hyvyyden perusteet

Tärkeimpänä mallin hyvyyden perusteena on sen yleinen toimivuus eli se, että malli pysyy toiminnassa ja tuottaa järkeviä tuloksia. Lisäksi, koska osa malleista voi olla hyvin työläitä niitä päivitettäessä, teollisuudessa toimittaessa on usein tärkeää, että mallit vaativat vain vähän huomiota, kun ne on saatu toimimaan. Muuten niiden käyttö saatetaan unohtaa rajallisten työresurssien vuoksi.

Validoinnissa parhaat tavat määrittää mallin hyvyttä ovat regressioanalyysi, keskiarvojen määrittäminen ja valvontakortit. Regressioanalyysillä saadaan yleinen kuva siitä, kuinka hyvä malli on, selitystasoon avulla. Lisäksi selitystasojen vertaileminen keskenään on hyvin yksinkertaista. Todellisten ja mallinnettujen arvojen keskiarvojen määrittämisellä on hyvin yksinkertaista löytää systemaattista alitusta ja ylitystä mallin toiminnassa. Tätä tarkastelua voidaan jatkaa tarkemmin aikasarjakuvaajan avulla, jolloin pystytään havaitsemaan ylityksiä ja alituksia yksittäisten sulatusten osalta. Valvontakortteja tekemällä pystyttiin helposti havaitsemaan se, kuinka suuri osa mallinnoista oli hyviä, tyydyttäviä ja huonoja, ja niissä mielestäni yhdistyi kaikkien muiden validointimenetelmien hyvät puolet. Tästä syystä mielestäni valvontakortit ovat paras tapa määrittää mallien hyvyttä ja seurata niiden toimintaa. Valvontakorttien avulla ei kuitenkaan pystytä toteamaan millaisissa tilanteissa mallit toimivat huonosti, ja mistä tämä huonosti toimivuus voi johtua.

Kun tarkastellaan validoinnin tuloksia, on tärkeää ottaa huomioon, milloin mallinnus on tehty. Osassa malleista mallinnus on suoritettu ennen sulatusta, osassa sen aikana ja osassa sulatuksen lopetuksen jälkeen. Täten malleilla on käytössä täysin eri määrä dataa sulatuksesta mallinnuksen luontiin.

## 7.3 Paukku

Kuten luvussa 6 kerrottiin, panoslaskentaa eli Paukkua käytetään reseptien laskemiseen sekä esilaskentaan, kun toteutunut panos tiedetään. Kaatopainon osalta validoinnissa

pystyttiin toteamaan, että Paukku systemaattisesti mallintaa kaatopainon liian korkeaksi reseptissä sekä esilaskennassa. Todennäköisimpänä syynä tähän on se, että Paukku ei ota huomioon sitä osaa teräksestä, joka kulkeutuu ulos uunista joko savukaasujen mukana tai päätyy kuonaan.

Reseptiä laskettaessa Paukku oli systemaattisesti määrittänyt hiili- ja piipitoisuudet liian korkeiksi. Tähän epäiltiin syyksi tarkoituksellista hiilipitoisuuden laskua, jonka tarkoituksena on ollut hillitä sulan kuohumista kaadon aikana. Kuitenkin myös esilaskentavaiheessa pystyttiin havaitsemaan datasta systemaattinen liian korkea hiilipitoisuuden mallinnus. Nikkelipitoisuuden laskennan osalta Paukku suoriutui hyvin kummassakin tapauksessa. Kromipitoisuuden laskussa Paukku suoriutui paremmin reseptiä laskettaessa kuin esilaskentavaiheessa keskiarvon osalta. Tähän syinä voivat olla datan käyttö eri sulatuksista tai se, että esilaskennassa piipitoisuus on määritetty kiinteäksi arvoksi. On myös mielenkiintoista nähdä, että kuvan 46 perusteella esilaskentavaiheessa tiedostetaan, että aina ei päästä haluttuun 137 tai 139 tonnin kaatopainoon. Lisäksi operaattorien mielestä Paukku määrittelee lisättävän ferropiin määrän liian korkeaksi esilaskentavaiheessa.

## **7.4 2-tason prosessimallit**

2-tason mallit Outokummulla ovat unohdettuja malleja eli ne pyörivät 2-tason järjestelmässä ja mallintavat sulatusta, mutta niitä ei käytetä tällä hetkellä mihinkään ainakaan tietävästi. Lisäksi malleja ei päivitetä ollenkaan, vaikka ne vaatisivat päivitystä toimiakseen tehokkaasti. Näistä luvussa 5.4 käsitellyistä 2-tason malleista oli saatavilla dataa energiamallista ja raffinointimallista Qmadossa.

### **7.4.1 Energiamalli**

Kaatolämpötilan osalta validointi oli jo lähtökohtaisesti virheellinen, koska verrattiin uunissa olevan teräksen lämpötilan mallinnusta mitattuihin kaatolämpötiloihin. Oli kuitenkin mielenkiintoista nähdä, että mallinnetut lämpötilat uunissa olivat merkittävästi matalampia kuin mitatut lämpötilat kaadon jälkeen. Koska kaikki mallinnukset, joita käytettiin validoinnissa, olivat tilanteesta, jossa malli ei suositellut lisättäväksi energiaa sekä tiedettiin, että mallinnus oli suoritettu maksimissaan viisi minuuttia ennen kaatoa, voidaan olettaa, että malli systemaattisesti mallintaa teräksen lämpötilan liian matalaksi uunin sisällä.

### 7.4.2 Raffinointimalli

Kuten energiamallissa myös raffinointimallissa validointi oli jo lähtökohtaisesti virheellinen, koska verrattiin uunissa olevan teräksen koostumuksen mallinnusta 7-näytteeseen, joka otetaan kaadon jälkeen. Raffinointimallin piipitoisuuden laskenta on selkeästi virheellinen, koska noin 35 %:ssa sulatuksista malli on mallintanut piipitoisuuden olevan 0 %. Vertailtaessa selityksasteita oli mielenkiintoista nähdä, kuinka selityksasteen perusteella raffinointimalli suoriutuu hiilipitoisuuden mallinnuksesta paremmin kuin Paukku.

## 7.5 MORSEVKU2

Diplomityötä tehtäessä MORSEVKU2-malli oli vasta kehitysvaiheessa ja kehitystä mallissa tapahtui jatkuvasti diplomityönaikana. Validoinnin versioissa yksi ja kaksi käytettiin osaksi samoja sulatuksia, mutta mallinnukset oli tuotettu mallin eri versioilla, joista versio kaksi on uudempi versio.

### 7.5.1 Kaatopainomallin korjaus

Luvuissa 6.1.1 ja 6.1.2 tehdyssä kaatopainomallin validoinnissa havaittiin, että systemaattisesti malli oli mallintanut kaatopainon noin 10 tonnia liian korkeaksi. Mallinnuksen virheeksi selvisi virheelliset oletukset mallin luonnissa. Kuvassa 83 on esitetty luvun 6.1.2 valvontakortti korjatulla kaatopainolla. Korjattu kaatopaino on laskettu vähentämällä kaikista mallinnustuloksista 10 tonnia. Kuten valvontakortista nähdään, 60,8 % mallinnustuloksista on hyviä tai tyydyttäviä ja vain 39,2 % on huonoja. Vaikka mallin suorituskyky valvontakortin perusteella ei ole vielä halutulla tasolla, voidaan nähdä, että mallin kehitystä jatkettaessa on mahdollista parantaa mallin suorituskykyä.



Kuva 83. Valvontakortti: Mallinnettu kaatopaino ja mitattu kaatopaino (MORSEVKU2 korjattu).

## 7.6 Sulatusajan optimointimalli

Sulatusajan optimointimallin validoinnissa kaksi keskeisintä asiaa olivat korkein selitysaste kaatopainomallille ja se, kuinka datan perusteella operaattorit olivat käyttäneet mallia. Korkeimman selitysasteen lisäksi mallin suoriutuminen valvontakortin perusteella oli erinomaista verrattuna muihin malleihin. Lisäksi validoinnissa ei havaittu samaa noin kahden tonnin ylitystä mallinnustuloksessa kaatopainon osalta kuin muissa malleissa, mikä johtuu todennäköisesti siitä, että sulatusajan optimointimalli ottaa huomioon, että osa teräksestä päätyy kuonaan ja savukaasujen mukana ulos uunista. Lähes 50 %:ssa datasta operaattorit olivat seuranneet mallinnustulosta  $\pm 10$  kWh/t tarkkuudella, minkä perusteella voidaan olettaa, että heidän mielestään mallissa on potentiaalia prosessiohjauksen kehityksen kannalta. Lisäksi datasta pystyttiin toteamaan, että malli toimii hyvin tilanteissa, jotka ovat normaaleja. Tämän perusteella mallin voidaan siis olettaa toimivan valtaosan ajasta hyvin.

## 7.7 Kilpailevat mallit MORSEVKU2 ja Sulatusajan optimointimalli

MORSEVKU2-mallia ja Sulatusajan optimointimallia kehitettiin yhtäaikaaisesti kevään aikana, ja ne olivat kilpailevia malleja eli niiden tarkoituksena oli mallintaa samoja parametrejä. Eroina malleissa oli niiden lähestymistapa mallinnukseen. MORSEVKU2-malli oli enemmän prosessiymmärryslähtöinen, kun taas sulatusajan optimointimalli perustui enemmän tilastoihin. Tämän vuoksi MORSEVKU2-malli pystyi mallintamaan paremmin sulatuksia, jotka poikkesivat merkittävästi normaalista. Sulatusajan optimointimallin tilastollisen mallinnuksen vuoksi sen antamat tulokset olivat yleensä lähellä keskiarvoisesti normaaleja sulatuksia, minkä vuoksi se ei pystynyt mallintamaan tehokkaasti sulatuksia, jotka poikkesivat merkittävästi normaalista. MORSEVKU2-mallin validoinnissa käytetyt mallinnukset on tehty prosessidatasta sen jälkeen, kun prosessi on jo päättynyt. Vastaavasti sulatusajan optimointimallin mallinnukset on tehty ennen kuin sulatus on loppunut. Tästä syystä MORSEVKU2-mallilla on ollut käytössä siis enemmän ja laadukkaampaa dataa mallinnuksen kannalta kuin sulatusajan optimointimallilla.

Energiamallien osalta mallien vertailu on turhaa niiden hyvin erilaisen toiminnan vuoksi. Sulatusajan optimointimalli mallintaa, paljonko energiaa tulisi syöttää, ja MORSEVKU2-malli mallintaa, paljonko energiaa on syötetty. Kuitenkin niiden

kaatopaino- ja kaatolämpötilamallien vertailu on mahdollista. Selityksasteiden ja valvontakorttien perusteella sulatusajan optimointimalli toimii paremmin mallinnettaessa kaatopainoa. Lämpötilamallin osalta MORSEVKU2-malli suoriutuu paremmin selityksasteen perusteella, mutta valvontakorttien perusteella mallien toiminta on hyvin lähellä toisiaan. Tämän vuoksi tilanteissa, joissa halutaan mallintaa kaatopainoa ja kaatolämpötilaa normaalitilanteessa, on järkevintä käyttää sulatusajan optimointimallia. Kuitenkin validointia suorittaessa huomattiin, että sulatusajan optimointimallin kyky havaita normaalista poikkeavia tilanteita on hyvin heikko. Vastaavasti MORSEVKU2-malli pystyi havaitsemaan näitä poikkeavia tilanteita. Taulukossa 20 on esitetty kummankin mallin valvontakorttien tulokset.

Taulukko 20. Sulatusajan optimointimallin ja MORSEVKU2-mallin valvontakorttien tulokset.

Malli ja mallinnettava suure	Hyvä mallinnus	Tyydyttävä mallinnus	Huono mallinnus
MORSEVKU2 v1 (kaatopaino)	6,8 %	17,5 %	75,5 %
MORSEVKU2 v2 (kaatopaino)	9,3 %	20,6 %	70,1 %
MORSEVKU2 korjattu (kaatolämpötila)	27,1 %	33,7 %	39,2 %
Sulatusajan optimointimalli v1 (kaatopaino)	32,2 %	21 %	46,8 %
Sulatusajan optimointimalli v2 (kaatopaino)	49,2 %	30,7 %	20,1 %
MORSEVKU2 v1 (kaatolämpötila)	14,3 %	13,2 %	72,5 %
MORSEVKU2 v2 (kaatolämpötila)	22,4 %	20,6 %	57,0 %
Sulatusajan optimointimalli v1 (kaatolämpötila)	16,0 %	30,0 %	54,0 %
Sulatusajan optimointimalli v2 (kaatolämpötila)	23,3 %	28,3 %	48,1 %

## 7.8 Köhlen malli

Vaikka Köhlen vuoden 2001 malli on hyvin yksinkertainen, sen avulla on pystytty mallintamaan kohtalaisesti sulattajan näkemystä tarvittavasta energiamäärästä. Tämän perusteella mallin kehittäminen voisi olla tarkastelun kohteena, koska jo hyvin yksinkertaisella mallilla on onnistuttu saamaan kohtalaisia tuloksia. Lisäksi nähdään, kuinka paljon parempi MORSEVKU2-mallin energiamalli on verrattuna tavalliseen Köhlen malliin. Tärkeintä Köhlen mallin testauksesta ja validoinnista saatu oppi on se, että jo hyvin yksinkertaisella mallilla voidaan saada kohtalaisia mallinnustuloksia. Malli



on myös hyvin helposti ymmärrettävissä ja siihen liittyen on tehty useita julkaisuja, joita on käyty läpi myös tässä työssä.

## **7.9 Yhteenveto validoinnin tuloksista**

Tässä luvussa avattiin tarkemmin validoinnin tuloksia. Oli mielenkiintoista havaita, kuinka mallien kehitys tämän työn aikana paransi niiden mallinnuskykyä, ja kuinka datasta pystyttiin havaitsemaan sulattajien käyttäytymistä. Lisäksi validoinnin avulla pystyttiin luokittelemaan, kuinka malleja tulisi tulevaisuudessa mahdollisesti käyttää.

### **7.9.1 Mallien suurimmat ongelmat yleisesti**

Koska Köhlen malli oli tarkastelluista malleista ainoa avoin malli, oli muiden mallien toimintaa hyvin vaikea ymmärtää ja arvioida kattavasti. Täten blackbox-mallit voivat aiheuttaa ongelmia teollisuuskäytössä. Mallien validointia suorittaessa havaittiin joitain ongelmia, jotka esiintyivät useissa malleissa. Kaatopainomalleissa havaittiin, että mallit eivät ottaneet huomioon, ettei kaikki teräs päädy senkkaan. Lisäksi pystyttiin havaitsemaan, että mallit systemaattisesti mallinsivat hiili- ja piipitoisuudet liian korkeiksi. Lisäksi joissain malleissa pystyttiin havaitsemaan hyvin yksinkertaisia systemaattisia virheitä.

### **7.9.2 Mallien hyvät ominaisuudet yleisesti**

Outokummun mallikokoelmassa oli kattava määrä malleja, jotka mallinsivat eri asioita useilla eri tavoilla. Kaatopainomalleissa havaittiin systemaattisesti, että ne eivät todennäköisesti ottaneet huomioon, ettei kaikki teräs päädy senkkaan. Oli kuitenkin hyvin kannustavaa kehityksen kannalta, kuinka validoinnin perusteella sulatusajan optimointimallissa tämä oli otettu huomioon. Toinen kehitykseen liittyvä parannus oli luvussa 7.5.1 korjattu systemaattinen virhe. Näiden kahden seikan takia mielestäni on siis kannattavaa jatkaa mallien kehitystä niiden toiminnan parantamiseksi.

## 8 PROSESSIMALLIEN KEHITYSIDEAT

Tässä luvussa on esitetty näkemyksiä siitä, kuinka prosessimallien kehitykseen pitäisi suhtautua tulevaisuudessa. Mielipiteet perustuu validoinnista saatuihin tuloksiin, vertailuun kirjallisuudessa esitettyihin malleihin ja Outokummun henkilökunnalta saatuihin näkemyksiin. Tässä työssä ei käyty läpi sitä, kuinka mallien toimintaa voitaisiin tai tulisi yhdistää, mutta myös tämä voisi olla yksi jatkotutkimuksen suunnista. Tämän lisäksi tulisi tehdä kattava kartoitus siitä, ketkä käyttävät malleja ja voitaisiinko mallien käyttöä lisätä henkilökunnan keskuudessa. Viimeiseksi olisi ollut hyvin mielenkiintoista tutkia, kuinka hyvin sulattajat pystyisivät arvioimaan kaatopainon ja kaatolämpötilan ja vertailla näitä arvoja mallien mallinnuskykyyn. Tämä kuitenkin jäi tekemättä vallitsevan koronatilanteen vuoksi.

### 8.1 Mallien toiminnan seuraaminen

Validoinnin aikana havaittiin, että valvontakortit, joiden avulla on havainnollistettu eri mallien toimivuutta luvussa 6, ovat paras tapa seurata sitä, kuinka hyvin mallit suoriutuvat. Niiden avulla pystytään selkeästi seuraamaan, koska malli on toiminut hyvin, ja luokittelemaan kuinka suuri osa mallinnuksista on ollut hyviä, tyydyttäviä tai huonoja. Lisäksi malleja tulisi seurata jatkuvasti, jotta pystyttäisiin havaitsemaan, jos niiden toiminta heikkenee. Lisäksi pystyttäisiin samalla kehittämään malleja, jos huomataan, että mallit systemaattisesti toimisivat huonosti tietyissä tilanteissa. Myös selitysasteet ovat hyvin nopea ja selkeä tapa seurata mallien toimintaa, mutta pelkästään niiden avulla ei voida luoda kattavaa kuvaa mallien toiminnasta, koska ne eivät ota huomioon sitä, kuinka suuria mallinnusvirheet ovat. Mallinnustulokset voitaisiin myös jakaa onnistuneisiin sekä epäonnistuneisiin ja tämän jälkeen tutkia näitä sulatuksia merkitsevien tekijöiden perusteella.

### 8.2 Täysin uusi malli

Jos VKU2:lle tulisi ehdottaa yhtä täysin uutta mallinnustapaa, lähestymistavaksi voisi valita samantapaisen mallin kuin Gajicin et al. (2016) julkaisussa. Tällöin koneoppimisen avulla pystyttäisiin mallintamaan energiantarvetta ja etenkin käyttämään hyväksi SulO:a, joka jatkuvasti itseoppii lisää jokaisesta romuerästä. Näiden kahden avulla olisi siis mahdollista mallintaa ehkä jopa hyvin tarkasti energiantarvetta prosessille ottamalla

huomioon raaka-aineet erityisen tarkasti. Toinen maininnan arvoinen lähestymistapa olisi Logarin & Dovzanin (2012) julkaisuihin perustuvan mallin luonti, koska siitä on olemassa hyvin kattavia julkaisuja ja se eroaisi nykyisin käytössä olevista malleista.

### **8.3 Simulaattorin kehitys**

Jos VKU2:sta onnistuttaisiin kehittämään toimiva simulaattori, sen avulla olisi mahdollista kouluttaa uusia operaattoreita ja erityisesti opettaa heille tilanteita, joita tapahtuu valokaariuuniprosessissa harvoin. Täten tehokkaan operaattorien koulutuksen avulla pystyttäisiin laajentamaan osaamista työntekijöiden keskuudessa ja sen avulla vähentämään tilanteita, joissa tuotanto joudutaan keskeyttämään henkilöstöpulan vuoksi. Lisäksi simulaattorilla voitaisiin mahdollisesti kokeilla ja valmistautua sulatuksiin, jotka poikkeavat merkittävästi normaalista.

### **8.4 Paukku**

Validoinnissa havaittiin systemaattisesti, että Paukku mallintaa hiili- ja piipitoisuudet liian korkeiksi reseptivaiheessa sekä hiilipitoisuuden liian korkeaksi esilaskentavaiheessa. Tätä tulisi tutkia ja selvittää syyt, miksi näin tapahtuu ja onko tämä tahallista. Samalla tulisi käydä läpi, miksi piipitoisuuden mallinnus on asetettu vakioksi esilaskentavaiheessa, sekä tarkastaa, ottaako malli huomioon sen, että osa teräksestä päättyy savukaasujen mukana ulos uunista ja osa kuonaan.

### **8.5 Sulatusajan optimointimalli ja MORSEVKU2-malli**

Luvussa 6 esitettyjen validointien perusteella molempien mallien kehitystä tulisi jatkaa yhtäaikaaisesti, koska vaikka ne mallintavat samoja asioita, ne mallintavat niitä hyvin erilaisilla tavoilla ja näin täydentävät toisiaan. Lisäksi validoinnin aikana pystyttiin havaitsemaan kehitystä mallien mallinnuskyvyssä. Kun mallit valmistuvat, tulisi miettiä hyvin tarkkaan, kenen malleja tulisi käyttää ja mihin käyttöön mallit soveltuvat parhaiten. Lisäksi niiden kehitystä tulisi jatkaa myös niiden virallisen valmistumisen jälkeen. Muutoin niille tulee todennäköisesti käymään kuten 2-tason malleille, jotka on unohdettu. Kuten aiemmin mainittiin nämä mallit molemmat käyttävät hyväksi THD:ta eli säröä. THD:ta voidaan jatkossa käyttää Luxmetin ArcSpec-mittalaitteiden validoinnissa VKU2:lla.

### **8.5.1 Sulatusajan optimointimallin korrelaatiokertoimien tutkiminen**

Sulatusajan optimointimallin ollessa tilastollinen malli olisi kannattavaa tutkia mallinnettujen kaatopainojen, kaatolämpötilojen ja energioiden korrelaatioita ja verrata niitä vastaaviin toteutuneisiin arvoihin. Näin pystyttäisiin havaitsemaan mahdollisesti, kuinka malli ottaa huomioon sen, kuinka paljon lisää energiaa tarvitaan lämmittämään suurempi panos tai kuinka energiankäyttö vaikuttaa lämpötilaan.

## **8.6 Energiamalli ja Köhlen malli**

Jos energiamallia tai Köhlen mallia lähdetään kehittämään VKU2:lla, tulisi ennen tätä tutkia, kumman kehittäminen olisi kannattavampaa. Energiamallin etuna on, että se on jo jokseenkin valmis. Tämä on myös sen suuri heikkous, koska vaikka se on ollut hyvin kauan aikaa toiminnassa, sitä ei ole käytetty ja se on unohdettu. Köhlen mallin etuna vastaavasti on se, että se on hyvin yksinkertainen ja helposti ymmärrettävissä ja kehitettävissä. Selitysasteiden puolesta mallit ovat lähellä toisiaan eikä tämän perusteella voida päätellä kumman kehittäminen olisi kannattavampaa. Tässä työssä tehtyjen havaintojen pohjalta itse valitsisin Köhlen mallin. Tämä johtuu siitä, että hyvin todennäköisesti tätä yksinkertaista mallia saataisiin kehitettyä vähällä vaivalla paremmin toimivaksi Outokummun oman henkilökunnan toimesta. Lisäksi mallin luonnissa voitaisiin käyttää hyväksi muiden mallien kaatopainon ja kaatolämpötilan mallinnusta.

## **8.7 Yhteenveto prosessimallien tulevaisuudesta**

Tärkein asia tulevaisuudessa mallinnustavasta riippumatta on se, että mallien kehitystä jatketaan koko ajan ja että niitä ei unohdeta. Työn aikana havaittiin, kuinka joitain malleja oli unohdettu kokonaan ja kuinka niiden mallinnuskyvystä kenelläkään ei ollut kattavaa näkemystä. Tämä sama tulee siis todennäköisesti toistumaan tällä hetkellä kehitettävillä malleilla, jos niiden ylläpitoon ja tarkkailuun ei käytetä aikaa. Lisäksi, koska mallinnustapoja on kirjallisuudessa todella paljon, tulisi mallikokoelmaan valita malleja, jotka ovat mahdollisimman erilaisia. Tällöin, jos yksi malli ei toimi, jossain tilanteessa toinen malli voi korvata sen puutteita tietyillä alueella. Tätä oli havaittavissa jo MORSEVKU2-mallissa ja sulatusajan optimointimallissa normaalista poikkeavien sulatusten osalta. Viimeiseksi se, nähdäänkö mallin sisään eli pystytäänkö sen toimintaa tarkastelemaan, on hyvin tärkeää Outokummun kannalta. Tällöin mallin kehittäminen ja

toiminnan ymmärtäminen on huomattavasti helpompaa kuin mallin, jonka toimintaa ei ymmärretä täydellisesti. Lisäksi pystytään välttämään yksi välikäsi, koska ei tarvita toimittajaa, joka tekee muutokset malliin.

## 9 YHTEENVETO

Prosessimallien avulla on tarkoitus tehostaa ja tutkia valokaariuuniprosessia. Tässä työssä tarkasteltiin Outokummun Tornion tehtaalle kehitettyjä prosessimalleja ja vertailtiin niitä. Työn alussa käytiin läpi VKU2:n toimintaa ja sitä, mitkä tekijät vaikuttavat energiantarpeeseen valokaariuuniprosessissa. Energiantarve on hyvin merkittävä tekijä prosessissa, ja sen avulla on mahdollista tehdä säästöjä prosessin aikana käyttämällä optimimäärä energiaa jokaiseen sulatukseen. Näiden kahden ensimmäisen luvun avulla lukija saa käsityksen siitä, millainen mallinnuskohde valokaariuuni on.

Luvussa 5 on kerätty tietoa useasta lähteestä ja eri henkilöiltä ja luotu kuvaus VKU2:lla käytössä olevista malleista, minkä perusteella lukija saa kattavan perusymmärryksen malleista. Tätä perusymmärrystä lukija voi laajentaa luvussa 4 esitetyillä malleilla ja samalla vertailla, kuinka VKU2:lla käytössä olevat mallit eroavat kirjallisuudessa esitetyistä malleista ja kuinka VKU2-mallikokoelmaa olisi mahdollista laajentaa tulevaisuudessa. Keskeisenä havaintona nousee esiin se, kuinka monin eri tavoin valokaariuuniprosessia voidaan mallintaa. Myöskään mikään yksittäinen mallinnustapa ei noussut ylitse muiden.

Validointi, joka oli tämän diplomityön tutkimusosuus, nosti esiin useita erittäin mielenkiintoisia havaintoja. Tämä diplomityö on hyvin laaja sen vuoksi, että työssä tutkittiin useita erilaisia malleja. Osa malleista myös jäi validoimatta tämän työn aikana, mutta validoinnin aikana silti ilmeni useita asioita mallien toiminnasta, joita voidaan hyödyntää jatkossa. Yhden mallin läpikäyntiin ja validointiin olisi ollut mahdollista käyttää yhtä paljon aikaa kuin nyt käytettiin koko työhön.

Työn loppuosassa esiteltiin validoinnin tuloksia, ja näistä voidaan erityisesti tuoda esiin se, kuinka mallit kehittyivät validoinnin aikana. Tämä johtuu siitä syystä, että vaikka mallit olisivat virallisesti valmiita, niiden kehitystä tulisi jatkaa silti, koska todennäköisesti pystyttäisiin tekemään samankaltaisia parannuksia niiden toiminnassa. Erityisen tärkeää on mallien jatkuva ylläpito. Kehitettäessä VKU2:n malleja tulevaisuudessakannattaa tutustua Gajicin et al. (2016) ja Logarin & Dovzanin (2012) julkaisuihin ja arvioida, olisiko tällaisten mallien kehitys VKU2:lle järkevää. Samalla tulisi miettiä ehdotusta simulaattorista, jonka avulla operaattorien koulutus olisi tehokkaampaa.

## 10 LÄHDELUETTELO

Arzt, K. (2004). Level 2 automation – detailed technical specification process models. VAI.

Auer, Eero. (2020). Outokumpu Stainless Oy. Keskustelut talven aikana.

Baumert, J.-C.; Engel, R.; Weiler, C. (2002). Dynamic modelling of the electric arc furnace process using artificial neural networks. *Revue de Métallurgie* 2002, 99, 839–849.

Bianco, Loris & Porisiensi, Sergio & Baracchini, Giulia & Battigelli, Laura & Ceschia, Carlo. (2018). Circular Economy in EAF Process: How to Make It Sustainable with Zero Waste Project in Ferriere Nord. *Universal Journal of Management*. 6. 190-197. 10.13189/ujm.2018.060602.

Camdali, Unal & Yetişken, Yasar & Ekmekci, Ismail. (2012). Determination of the Optimum Cost Function for an Electric Arc Furnace and Ladle Furnace System by Using Energy Balance. *Energy Sources, Part B: Economics, Planning, and Policy*. 7. 200-212. 10.1080/15567240903030521.

Carlsson, Leo & Samuelsson, Peter & Jönsson, Pär. (2019). Predicting the Electrical Energy Consumption of Electric Arc Furnaces Using Statistical Modeling. 9. 959. 10.3390/met9090959.

Carlsson, Leo & Samuelsson, Peter & Jönsson, Pär. (2019b). Using Statistical Modeling to Predict the Electrical Energy Consumption of an Electric Arc Furnace Producing Stainless Steel. *Metals*. 10. 36. 10.3390/met10010036.

Chen Chong, Liu Ying, Kumar Maneesh and Qin Jian. (2018). Energy consumption modelling using deep learning technique — a case study of EAF. *Procedia CIRP* 72, pp. 1063-1068.

Echterhof, Thomas & Hay, Thomas & Pfeifer, Herbert. (2018). A Dynamic EAF Process Model - State of development and outlook.

Fabritius, Timo. (2009) Hapetus- ja pelkistysreaktiot sulassa teräksessä. Oulun yliopisto, Prosessi- ja ympäristötekniikan osasto.

Gajic, Dragoljub & Savic-Gajic, Ivana & Savic, Ivan & Georgieva, Olga & Di Gennaro, Stefano. (2016). Modelling of electrical energy consumption in an electric arc furnace using artificial neural networks. *Energy*. 108. 132-139. 10.1016/j.energy.2015.07.068.

Gramberger, Knapp. (2001) Valokaariuunin tekninen prosessikuvaus, FSL-Doc.No. OTF.SE.2/PBS001. 49 s.

Hasa, Janika. (2016). Valokaariuunin savukaasujen hallinta ja imutehojen optimointi. Diplomityö. Oulun yliopisto.

Hay, Thomas & Echterhof, Thomas & Visuri, Ville-Valtteri. (2019). Development of an Electric Arc Furnace Simulator Based on a Comprehensive Dynamic Process Model. *Processes*. 7. 852. 10.3390/pr7110852.

Hyttinen, Niko. (2020). Outokumpu Stainless Oy. Keskustelut talven aikana.

Hyttinen, Niko. (2013). Kierrätysteräksen laadun vaikutus valokaariuuniprosessissa tapahtuvaan kaasunmuodostukseen. Diplomityö. Oulun yliopisto.

Jokilaakso A (1987) Virtaustekniikan, lämmönsiirron ja aineensiirron perusteet, Otakustantamo 1987, 194 s. ISBN 951-672-015-3.

Karassaari, Olli-Pekka. (2008). Valokaariuunin energiatase ja kaatolämpötilan mallinnus. Diplomityö. Oulun yliopisto.

Kirschen M (2006). Energieeffizienz und emissionen der lichtbogenöfen in der stahlindustrie, Steel research library 2007, Verlag Stahleisen GmbH, Düsseldorf. 211 s. ISBN: 978-3-514-00739-0.

Kirschen, Marcus & Kronthaler, Andreas & Rahm, Christian. (2007). Impact of Water Cooled Copper Blocks in Refractory Linings on the Energy Balance of Electric Arc Furnaces.



Kirschen, Marcus & Pfeifer, Herbert & Wahlers, Franz-Josef. (2002). Mass and energy balances of stainless steel EAF.

Kirschen, Marcus & Velikorodov, Viktor & Pfeifer, Herbert & Wahlers, Franz-Josef. (2004). Modeling and optimization of EAF dedusting system.

Kirschen, Marcus & Velikorodov, Viktor & Pfeifer, Herbert & Kühn, Robert & Lenz, Stefan & Loh, Jürgen & Schäfers, Klaus. (2005). Off-gas measurements at the EAF primary dedusting system.

Kirschen, Marcus & Zettl, Karl-Michael & Echterhof, Thomas & Pfeifer, Herbert. (2017). Models for EAF energy efficiency. Steel Times International. 44.

Kunelius, Juho. (2010). Valokaariuuni 2:n kaatolämpötilan mallinnus. Diplomityö. Oulun yliopisto.

Kunelius, J. & Vallo, K. (2015). DynArCOS vaikutukset VKU2-prosessiin. Outokummun sisäinen raportti. TRC20150022.

Logar, Vito & Dovzan, Dejan. (2012). Modeling and Validation of an Electric Arc Furnace: Part 1 & 2, Heat and Mass Transfer. ISIJ International. 52. 402-412. 10.2355/isijinternational.52.402.

Malfa, Enrico & Crippa, F. & Frittella, P. & Scotto, M. (2009). APPLICATION OF CFD AT EAF PROCESS SIMULATION.

Metallinjalostajat ry (2014) Teräskirja 9. painos. Porvoo: Bookwell Oy

Migas, Piotr & Karbowniczek, Mirosław. (2013). Selected Aspects of Graphite Applications in Ferrous Metallurgy. AGH-University of Science and Technology, Department of Ferrous Metallurgy, Faculty of Metals Engineering and Industrial Computer Science.

Nikolaev, Alexander & Tulupov, P.G. & Astashova, G.V (2016). The Comparative Analysis of Electrode Control Systems of Electric Arc Furnaces and Ladle Furnaces. 10.1109/ICIEAM.2016.7910888.

Oinas, Miikka. (2009). Savukaasujen jatkuvatoiminen mittaus VKU2:n ohjauksen kehittämisessä. Diplomityö. Oulun yliopisto.

Oosthuizen, D.J & Craig, Ian & Pistorius, P. (2001). Design of an electric arc furnace based on economic objectives. Department of Electrical, Electronic and Computer Engineering. University of Pretoria. Pretoria.

Oosthuizen, D.J & Craig, Ian & Pistorius, P. (2004). Economic evaluation and design of an electric arc furnace controller based on economic objectives. Control Engineering Practice. 12. 253-265. 10.1016/S0967-0661(03)00078-9.

Oulun yliopisto (2019a). Terästen valmistus ja ominaisuudet. Ruostumattomat teräkset – johdanto ominaisuuksiin, valmistukseen ja metallurgiaan. Oulu: Materiaali- ja tuotantotekniikan tutkimusyksikkö.

Oulun yliopisto (2019b). Metallien valmistus nyt ja tulevaisuudessa. Digitalisaatio metallurgiassa: Case Luxmet. Oulu: Prosessimetallurgian tutkimusyksikkö. Matti Aula

Pfeifer, Herbert & Kirschen, Marcus. (2002). Thermodynamic analysis of EAF electrical energy demand. 8th European Electric Steelmaking Conference.

Pfeifer, Herbert & Kirschen, Marcus & Simoes, Jean-Paul. (2005). Thermodynamic analysis of electrical energy demand.

Reichel, J. & Rose, L. & Kempken, Jens & Damazio, M.A. & Carvalho, R.G. & Loss, Hélio & Pinto, E.M. & Dutra, J.R. & Karbowiczek, Mirosław. (2008). EAF-foamy slag in stainless steel production new extremely efficient technology easy to handle and cost-efficient. 53. 391-397.

Roininen J, Juntunen V, Leinonen V. (2008). VKU2 laskennan kehittäminen (päivitetty 6.2.2009). Tornio, Outokumpu Stainless Oy, Tutkimuskeskus, Raportti.

Sandberg, E. (2005). Energy and scrap optimisation of electric arc furnaces by statistical analysis of process data By.

Stephan Natschläger & Klaus Stohl. (2007). Metallurgical simulations of the EAF-process. IFAC Proceedings volumes. Volume 40, issue 11, pages 207-11.

Thampi, Ajay (2019). SO5 – Experimental Phase Report.

Vatron (2009). DynArCOS- Short overview of DynArCOS main functionality.

Veikko Heikkinen & Kirsti Loukola-Ruskeeniemi. (2015). Metallien jalostus Suomessa: nykytila ja tulevaisuuden haasteet. 7.1 Integroituminen jalostusketjussa vastavirtaan. s. 42

Wasbo, Stein & Jawahery, Sudi (2019). Application Specification Documentation - EAF2.

Wendelstorf, Jens & Spitzer, Karl-Heinz. (2006). A process model for EAF steelmaking. 2.

Wilson W, Kan M, Mirle A. (1998). Intelligent technologies for electric arc furnace optimization. ISS Technical paper.

Xi, Xiaojun & Yang, Shufeng & li, Jingshe & Wu, Jinqiang & Zhao, Mengjing & Ye, Maolin. (2019). Physical model experiment and theoretical analysis of scrap melting process in electric arc furnace combined blowing system. Ironmaking & Steelmaking. 1-9. 10.1080/03019233.2019.1594549.

Yildirim, Irem & Prezzi, Monica. (2011). Chemical, Mineralogical, and Morphological Properties of Steel Slag. Advances in Civil Engineering. 2011. 10.1155/2011/463638.

Yle. (2019). Outokumpu suunnittelee jätti-investointia Tornioon – uuden laitoksen hintaa ei kerrota, rakennusaika kaksi vuotta

Zhang, De-ming. (2011). Analysis for graphite electrode unit consumption in manufacturing system and use system of steel-making EAF. Nantong Yangzi Carbon Co.,Ltd.,Jiangsu Nantong 226002,China


LIITE 1. Taulukon 8 termit selitettynä. (Carlsson et al. 2019)

$E_{in,el}$	Total ingoing energy	$k$	Conductivity of the cooling panels
$E_{el}$	Total Electrical Energy (EE) output from transformer	$h$	Heat transfer coefficient of the EAF ambient gas
$E_{chem}$	Total energy from chemical reactions in steel and slag	$\epsilon$	Emissivity factor of the radiating surface area of the EAF
$E_{fu}$	Total energy input from burner	$\sigma$	Stefan-Boltzmann constant
$E_{out,el}$	Total outgoing energy	$\eta_{tr}$	Efficiency factor for the transformer system
$E_{steel}$	Total energy output into steel	$\eta_{arc}$	Efficiency factor for the energy transferred from the arcs
$E_{slag}$	Total energy lost in slag	$\eta_{fuel}$	Efficiency factor for burning the fuel in the burners
$E_{gas}$	Total energy lost in gas	$Q_{fuel}$	Heat generated per volume unit of fuel
$E_{dust}$	Total energy lost in dust	$V_{fuel}$	Volume of the fuel consumed by the burners
$E_{cooling}$	Total energy lost in cooling water	$A_{fl}$	Surface area of the EAF subject to convection losses
$E_{rad}$	Total energy lost through radiation	$A_{AC}$	Surface area of the cooling panels
$E_{conv}$	Total energy lost through convection	$A_{EAF}$	Surface area of the EAF subject to radiation losses
$E_{el,loss}$	Total energy lost in electrical system and arc transfer	$P_{avg}$	Average power of the transformer system
$T_{CS}$	The temperature of the cooling panels	$P$	Furnace pressure
$T_{EAF}$	The temperature of the surface area subject to radiation losses	$M$	Molar mass of the furnace gas
$T_s$	Temperature of ingoing material and gas at the start of the EAF process	$R$	Universal gas constant
$T_{tap}$	Temperature of the steel at tapping	$V_{gas}$	Volume flow of gas in the off-gas system
$T_{off/gas}$	Temperature of the off-gas leaving the EAF through the off-gas system		
$T_{cool}$	Temperature of the cooling water	$t_{TTT}$	Tap-to-tap time
$T_{fl}$	The temperature of the surface area subject to convection losses	$t_{on}/n$	Power-on time
$T_{amb}$	The temperature of the air surrounding the EAF	$t_i$	Delay time for delay type $i$
$m_{steel}$	Mass of ingoing metallic material	$k_i$	Gamma distribution shape parameter for delay type $i$
$m_{slag}$	Mass of ingoing onidic material	$\theta_i$	Gamma distribution scale parameter for delay type $i$
$\dot{m}_{dust}$	Mass flow of dust in the off-gas system	$t_{delay}^{tot}$	Total delay time imposed on a heat in the EAF process
$C_{steel}$	The heat capacity of steel at constant pressure	$K$	Number of nodes in the hidden layers
$C_{slag}$	The heat capacity of slag at constant pressure	$L$	Number of hidden layer
$C_{dust}$	The heat capacity of dust at constant pressure	$R^2$	Coefficient of determination
$C_{gas}$	The heat capacity of EAF ambient gas at constant pressure	$\bar{R}^2$	Coefficient of determination adjusted for number of data points and variables
$c_p(reactants)$	The heat capacity of reactants at constant pressure	$n$	Number of data points
$c_p(products)$	The heat capacity of products at constant pressure	$P$	Number of input variables
$\Delta H_{fo}^{std}(reactants)$	Standard heat of formation for reactants at 298K	$\rho_{X,Y}$	Correlation coefficient for variables X and Y
$\Delta H_{fo}^{std}(products)$	Standard heat of formation for products at 298K	$\sigma_X$	Standard deviation for variable X
$\Delta H_{fus,steel}$	Heat of fusion for steel	$\sigma_Y$	Standard deviation for variable Y
$\Delta H_{fus,slag}$	Heat of fusion for slag	$Err_{reg}$	Regular mean error
		$Err_{abs}$	Absolute mean error
		$Err_{RMS}$	Root mean square error
		$\beta_i$	True value of the output variable for data point $i$
		$\hat{\beta}_i$	Predicted value of the output variable for data point $i$

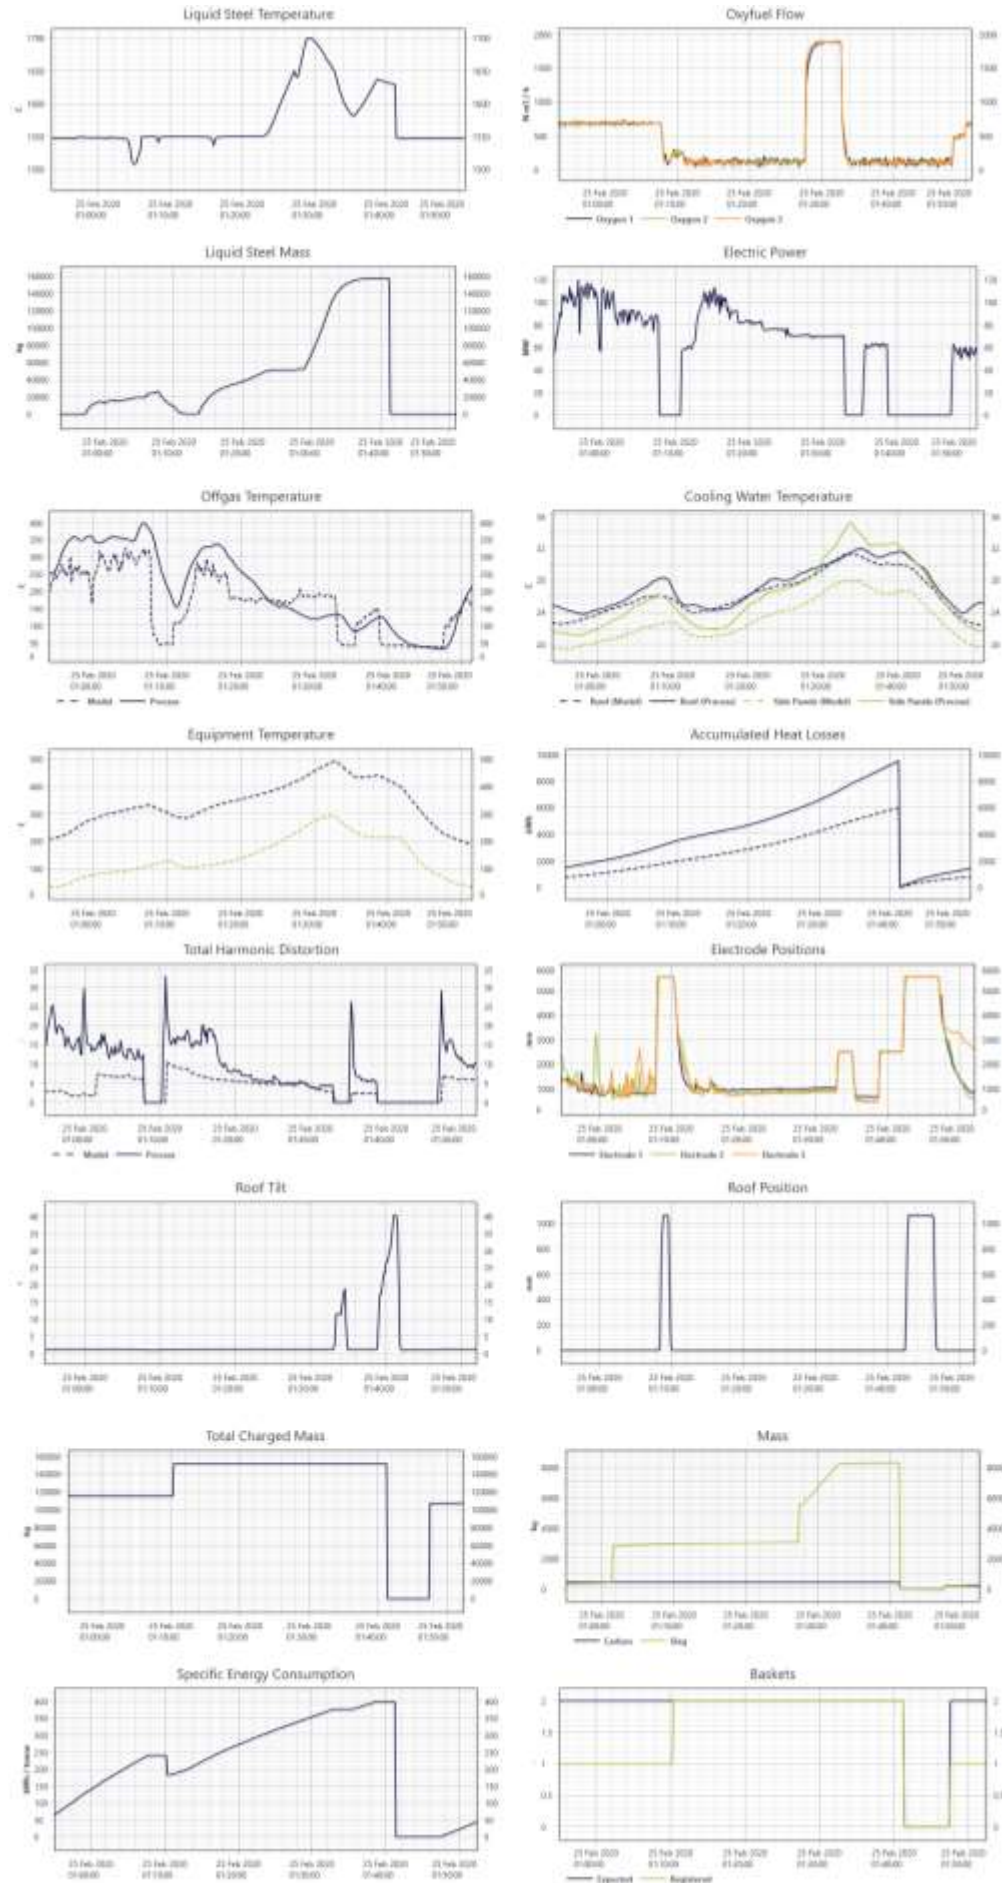
LIITE 2. Sulatusajan optimointimallin parametrit. (Thampi 2019)

Parametrit	Selitys
Vuorauksen ikä	Sulatusten määrä.
Al <sub>2</sub> O <sub>3</sub> amount	Komponentin paino panoksessa.
Al amount	Komponentin paino panoksessa.
C amount	Komponentin paino panoksessa.
CaO amount	Komponentin paino panoksessa.
Cr <sub>2</sub> O <sub>3</sub> amount	Komponentin paino panoksessa.
Cr amount	Komponentin paino panoksessa.
Fe <sub>2</sub> O <sub>3</sub> amount	Komponentin paino panoksessa.
Fe amount	Komponentin paino panoksessa.
H amount	Komponentin paino panoksessa.
MgO amount	Komponentin paino panoksessa.
MnO amount	Komponentin paino panoksessa.
Mn amount	Komponentin paino panoksessa.
Mo amount	Komponentin paino panoksessa.
N amount	Komponentin paino panoksessa.
Ni amount	Komponentin paino panoksessa.
O amount	Komponentin paino panoksessa.
SiO <sub>2</sub> amount	Komponentin paino panoksessa.
Si amount	Komponentin paino panoksessa.
TiO <sub>2</sub> amount	Komponentin paino panoksessa.
V <sub>2</sub> O <sub>5</sub> amount	Komponentin paino panoksessa.
prev heat energy	Edelliseen sulatukseen käytetty energia.
prev heat temperature	Edellisen sulatuksen kaatolämpö.
energy supply time diff	Tehot päällä ajan ero verrattuna edelliseen sulatukseen.
charged input weight	Panospaino.
Prev EAF Tapped weight	Edellisen sulatuksen kaatopaino.
Prev heat cooked status	Edellisen sulatuksen kaatolämpötilan ornistuminen.
Prev C 7	Edellisen sulatuksen hiilipitoisuus.
Prev SI 7	Edellisen sulatuksen piipitoisuus.
Prev MO 7	Edellisen sulatuksen molybdeenipitoisuus.
Prev S 7	Edellisen sulatuksen rikkipitoisuus.
Prev CR 7	Edellisen sulatuksen kromipitoisuus.
Prev NI 7	Edellisen sulatuksen nikkelipitoisuus.
Prev FE 7	Edellisen sulatuksen rautapitoisuus.
Prev P 7	Edellisen sulatuksen fosforipitoisuus.
Prev V 7	Edellisen sulatuksen vanadiinipitoisuus.
Prev CU 7	Edellisen sulatuksen kuparipitoisuus.
Prev CO 7	Edellisen sulatuksen hiilimonooksidipitoisuus.
Prev NB 7	Edellisen sulatuksen niobiumipitoisuus.
Prev AL 7	Edellisen sulatuksen alumiinipitoisuus.
Prev TI 7	Edellisen sulatuksen titaaniipitoisuus.
Prev MN 7	Edellisen sulatuksen mangaanipitoisuus.
Prev AS 7	Edellisen sulatuksen arseenipitoisuus.
Prev W 7	Edellisen sulatuksen volframipitoisuus.
Prev SN 7	Edellisen sulatuksen tinapitoisuus.
Prev heat weight deviation	Edellisen sulatuksen painon poikkeama halutusta 137t kaatopainosta.
hour of day	Ajankohta vuorokaudesta, jolloin sulatus on aloitettu.
months	Kuukausi, jolloin sula on sulatettu.
SteelGradeSeriesFlag	Haponkestävä- vai ruostumatonlaji


### LIITE 3. Demonäkymän historiatiedot.



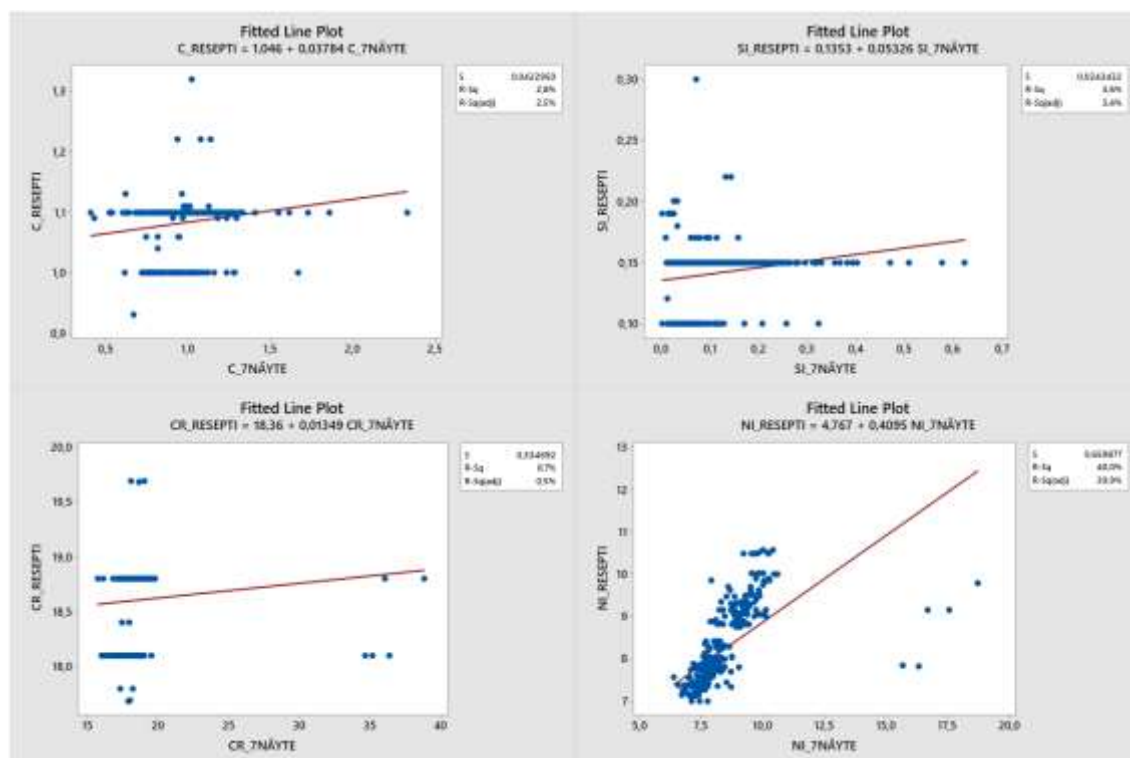
#### LIITE 4. Onlinenäkymän kaikki mallinnetut ja mitatut parametrit.



LIITE 5. Regressioanalyysi: Mallinnettu kaatolämpötila ja mitattu kaatolämpötila.  
(Sulatusajan optimointimalli v1)

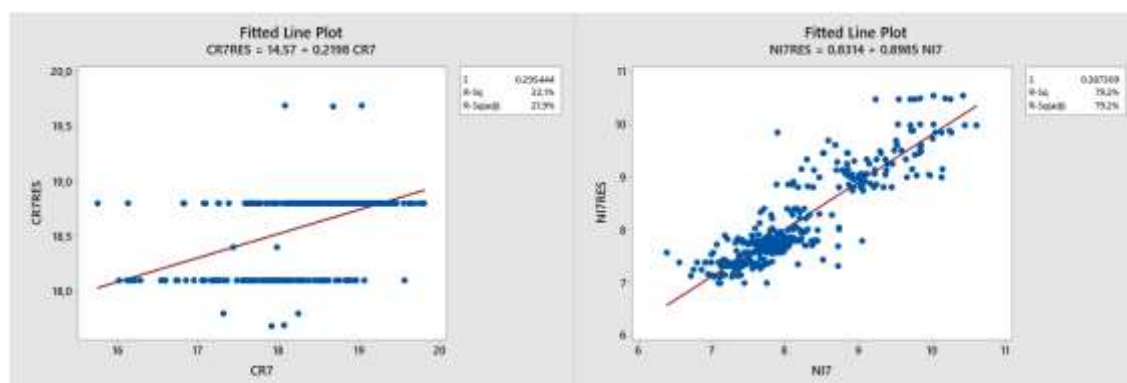


LIITE 6. Regressioanalyysi: Hiilen, piin, kromin ja nikkelin koostumus reseptissä ja sulassa. (Paukku)





LIITE 7. Regressioanalyysi: Kromin ja nikkelin koostumus reseptissä ja sulassa.  
(Paukku)



LIITE 8. Regressioanalyysi: Hiilen, piin, kromin ja nikkelin koostumus reseptissä ja sulassa. (Esilaskenta)

